

Habilidad predictiva de los modelos de la NOAA para predecir la precipitación en Colombia

Grupo de Modelamiento Numérico de Tiempo y Clima
Subdirección de Meteorología



Ambiente



IDEAM

PRESIDENCIA DE LA REPÚBLICA DE COLOMBIA

GUSTAVO FRANCISCO PETRO URREGO

Presidente de Colombia

FRANCIA MÁRQUEZ

Vicepresidenta de Colombia

MINISTERIO DE AMBIENTE Y DESARROLLO SOSTENIBLE

LENA ESTRADA AÑOKAZI

Ministra de Ambiente y Desarrollo Sostenible

MAURICIO CABRERA LEAL

Viceministro de Políticas y Normalización Ambiental

LILIA TATIANA ROA AVENDAÑO

Viceministra de Ordenamiento Ambiental del Territorio

CONSEJO DIRECTIVO

LILIA TATIANA ROA AVENDAÑO

Viceministra de Ordenamiento Ambiental del Territorio

PAOLA RICAURTE AYALA

Asesora de la Dirección de Ambiente y Desarrollo Sostenible, Departamento Nacional de Planeación (DNP)

ELKIN ERNESTO RAMÍREZ NIÑO

Director de la Dirección Técnica Geoestadística, Departamento Administrativo Nacional de Estadística (DANE)

ANDRÉS VÁSQUEZ LUNA

Director general (E) - Corporación para el Desarrollo Sostenible de La Mojana y el San Jorge (Corpomojana)

LILIANA MARÍA OSPINA ARIAS

Viceministra de Infraestructura (representación de la ministra de Transporte)

Instituto de Hidrología, Meteorología y Estudios Ambientales - Ideam

GHSILIANE ECHEVERRY PRIETO

Directora general

JUAN FERNANDO ACOSTA MIRKOW

Secretario general

FABIO ANDRÉS BERNAL QUIROGA

Subdirector de Hidrología

ELIZABETH PATIÑO CORREA

Subdirectora de Estudios Ambientales

RAYMOND ALEXANDER JIMÉNEZ ARTEAGA

Subdirector de Ecosistemas e Información Ambiental

DIANA CAROLINA RUEDA DIMATE

Subdirectora de Meteorología (E)

DIANA CAROLINA RUEDA DIMATE

Jefe de Oficina del Servicio de Pronóstico y Alertas

OLGA MARCELA VARGAS VALENZUELA

Jefe de Oficina Asesora de Planeación

WILMER ESPITIA MUÑOZ

Jefe de Oficina de Informática

GILBERTO ANTONIO RAMOS SUÁREZ

Jefe de Oficina Asesora Jurídica

ADRIANA MARÍA OCAMPO LOAIZA

Jefe de Oficina de Control Interno

MIGUEL ÁNGEL AYALA TOVAR

Coordinador del Grupo de Comunicaciones y Prensa

EQUIPO DE TRABAJO

Grupo de Modelamiento Numérico de Tiempo y Clima

Subdirección de Meteorología

Autores

JOSÉ FRANKLYN RUIZ MURCIA

JEIMMY YANELY MELO FRANCO

Coordinación editorial

ANDRÉS FELIPE TAPIERO RÍOS

Grupo de Comunicaciones y Prensa - Ideam

Edición y corrección de estilo

DIVA MARCELA PIAMBA TULCÁN

Grupo de Comunicaciones y Prensa - Ideam

Diseño editorial y diagramación

ALEJANDRO SEPÚLVEDA GAUER

Grupo de Comunicaciones y Prensa - Ideam

Créditos de las fotografías

Unsplash: • usgs • Waqar • Chamika Jayasr

Cítese como: Ruiz Murcia, J. F. y Melo Franco, J. Y. (2025). *Habilidad predictiva de los modelos de la NOAA para predecir la precipitación en Colombia*. Ideam.

ISBN: 978-958-5489-41-7

Publicación aprobada por el Instituto de Hidrología, Meteorología y Estudios Ambientales (Ideam).

Junio de 2025, Bogotá, D. C., Colombia.

Distribución gratuita.

Todos los derechos reservados. Los textos pueden ser usados parcial o totalmente citando la fuente. Su reproducción total o parcial debe ser autorizada por el Instituto de Hidrología, Meteorología y Estudios Ambientales (Ideam).

© Instituto de Hidrología, Meteorología y Estudios Ambientales

Calle 25 D No. 96 B - 70 - Bogotá, D. C.

PBX: +57 (601) 352 7160

contacto@ideam.gov.co

Habilidad predictiva de los modelos de la NOAA para predecir la precipitación en Colombia

Grupo de Modelamiento Numérico de Tiempo y Clima
Subdirección de Meteorología



Contenido

LISTA DE SIGLAS	5
LISTADO DE FIGURAS Y TABLAS	6
RESUMEN	8
ABSTRACT	9
INTRODUCCIÓN	10
DATOS UTILIZADOS	14
METODOLOGÍA (CONFIGURACIÓN DE LA CPT)	17
Estadísticos inferenciales	19
Correlación de Pearson	19
Correlación de Spearman	20
Índice de bondad	20
Estadísticos para variables continuas	20
MAE (Error Medio Absoluto)	20
RMSE (Error Cuadrático Medio)	21
LEPS (Error Lineal en la Probabilidad)	21
Estadísticos para múltiples categorías	21
2AFC (Prueba de selección forzada)	21
<i>Gerrity Score</i>	22
Estadísticos Dicotómicos	22
<i>Hit Score</i> (Tasa de aciertos)	22
DISCUSIÓN Y RESULTADOS	23
CONCLUSIONES Y RECOMENDACIONES	49
REFERENCIAS BIBLIOGRÁFICAS	52
ANEXO 1. CONTRIBUCIÓN DE CADA MODELO DE LA NOAA AL ENSAMBLE DE PREDICCIÓN	53

Lista de siglas

ACC: Análisis de Correlación Canónica

CIIFEN: Centro Internacional para la Investigación del Fenómeno de El Niño

CPC: Climate Prediction Center

CPT: Climate Predictability Tool

EOF: Funciones Empíricas Ortogonales

IRI: Instituto Internacional de Investigación sobre Clima y Sociedad

LEPS: Error Lineal en la Probabilidad

MAE: Error Medio Absoluto

NMME: Ensamble Multimodelo Norteamericano

OMM: Organización Meteorológica Mundial

PCR: Regresión de Componentes Principales

RMSE: Error Cuadrático Medio

ROC: Receiver Operating Characteristic o Característica Operativa del Receptor

SIG: Sistemas de Información Geográfica

TSM: Temperatura Superficial del Mar

WCRP: World Climate Research Project

ZCIT: Zona de Convergencia Intertropical

Listado de figuras

Figura 1. Factor de cambio para los siguientes seis meses con condiciones iniciales de enero.	37
Figura 2. Factor de cambio para los siguientes seis meses con condiciones iniciales de febrero.	38
Figura 3. Factor de cambio para los siguientes seis meses con condiciones iniciales de marzo.	39
Figura 4. Factor de cambio para los siguientes seis meses con condiciones iniciales de abril.	40
Figura 5. Factor de cambio para los siguientes seis meses con condiciones iniciales de mayo.	41
Figura 6. Factor de cambio para los siguientes seis meses con condiciones iniciales de junio.	42
Figura 7. Factor de cambio para los siguientes seis meses con condiciones iniciales de julio.	43
Figura 8. Factor de cambio para los siguientes seis meses con condiciones iniciales de agosto.	44
Figura 9. Factor de cambio para los siguientes seis meses con condiciones iniciales de septiembre.	45
Figura 10. Factor de cambio para los siguientes seis meses con condiciones iniciales de octubre.	46
Figura 11. Factor de cambio para los siguientes seis meses con condiciones iniciales de noviembre.	47
Figura 12. Factor de cambio para los siguientes seis meses con condiciones iniciales de diciembre.	48
Figura 13. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de enero.	53
Figura 14. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de febrero.	54
Figura 15. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de marzo.	55
Figura 16. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de abril.	56
Figura 17. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de mayo.	57
Figura 18. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de junio.	58
Figura 19. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de julio.	59
Figura 20. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de agosto.	60
Figura 21. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de septiembre.	61
Figura 22. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de octubre.	62
Figura 23. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de noviembre.	63
Figura 24. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de diciembre.	64

Listado de tablas

Tabla 1. Modelos dinámicos del CPC-NOAA	15
Tabla 2. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de enero.	25
Tabla 3. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de febrero.	26
Tabla 4. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de marzo.	27
Tabla 5. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de abril.	28
Tabla 6. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de mayo.	29
Tabla 7. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de junio.	30
Tabla 8. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de julio.	31
Tabla 9. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de agosto.	32
Tabla 10. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de septiembre.	33
Tabla 11. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de octubre.	34
Tabla 12. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de noviembre.	35
Tabla 13. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de diciembre.	36
Tabla 14. Mejores modelos de predicción de precipitación mensual para cada una de las condiciones iniciales.	50

Resumen

La predicción climática es un producto esencial proporcionado por los diferentes servicios hidrometeorológicos nacionales, cuyo objetivo es apoyar la planificación estratégica de actividades en diversos sectores socioeconómicos y ambientales. Entre estos sectores se incluyen la gestión del riesgo, la salud, la agricultura, la energía, entre otros.

En este contexto, la Administración Nacional Oceánica y Atmosférica (NOAA, por sus siglas en inglés) ha desarrollado un conjunto de modelos globales de baja resolución espacial, los cuales permiten realizar predicciones de algunas variables meteorológicas, como la precipitación, con un horizonte de hasta seis meses. No obstante, debido a la alta variabilidad climática espacial que caracteriza a Colombia, producto de su ubicación en la franja intertropical y su compleja topografía, estas predicciones requieren ser ajustadas a resoluciones espaciales más precisas.

En ese sentido, antes de utilizar estas predicciones de manera operativa, es fundamental evaluar la capacidad predictiva de los modelos de la NOAA con respecto a las observaciones, que fue el objetivo de este estudio. Para ello, se utilizó la climatología de referencia del período 1991 a 2020, que se dividió en dos mitades: la primera como período de control y la segunda como período de prueba. En el período de control, se establecieron relaciones estadísticas mediante el análisis de componentes principales entre el predictando del modelo (precipitación entre 15° N y 5° S de latitud, y entre 85° O y

65° O de longitud) y el predictor (precipitación estimada con datos satelitales [CHIRPS] en Colombia).

Una vez obtenidas las relaciones estadísticas del período de control, se aplicaron al período de prueba con el fin de evaluar la habilidad predictiva de los modelos para estimar la precipitación en Colombia. Para tal fin, se utilizaron métricas estadísticas inferenciales, tanto para variables continuas como para múltiples categorías y estadísticos dicotómicos.

El análisis de estas métricas permitió determinar la contribución de cada modelo de la NOAA en la predicción, lo que facilitó la creación de un ensamble ponderado. Este método asigna un peso a cada modelo según su desempeño. Con las ecuaciones del ensamble, se realizaron nuevas predicciones para el período de prueba, lo que permitió identificar las zonas donde el ensamble tendía a subestimar o sobrestimar la precipitación. Este análisis fue clave para generar un factor de corrección multiplicativo entre los valores observados y los predichos, útil para ajustar las predicciones operativas.

Como resultado, se observó que, en la construcción de los ensambles, ninguno de los modelos destacó significativamente por su habilidad predictiva frente a los demás, ni siquiera el ensamble de la NOAA, que corresponde al promedio de todos los modelos de baja resolución. En cambio, la metodología aplicada permitió identificar la contribución específica de cada modelo a la predicción.

Palabras claves: predicción climática, ensamble de modelos, análisis de correlación canónica, verificación de modelos climatológicos, predicción mensual del clima.

Abstract

Climate prediction is an essential product provided by various national hydrometeorological services, aimed at supporting the strategic planning of activities across different socioeconomic and environmental sectors. These sectors include risk management, health, agriculture, energy, and others.

In this context, the National Oceanic and Atmospheric Administration (NOAA) has developed a set of global low-resolution models that allow predictions of certain meteorological variables, such as precipitation, up to a horizon of six months. However, due to the high spatial climate variability that characterizes Colombia, resulting from its geographical location in the intertropical zone and its complex topography, these predictions need to be adjusted to finer spatial resolutions.


Before using these predictions operationally, it is essential to evaluate the predictive capacity of the NOAA models. To do this, we worked with reference climatology from 1991 to 2020, dividing this time series into two parts: the first half was used as the control period, and the second as the test period. During the control period, statistical relationships were established through Principal Component Analysis, between the model's predictand (precipitation between 15°N and 5°S latitude and between 85°W and 65°W longitude) and the predictor (precipitation derived from satellite data - CHIRPS - in Colombia).

Once the statistical relationships were obtained during the control period, these were applied to the test period to evaluate the predictive ability of the models to forecast precipitation in Colombia. For this, inferential statistical metrics were used, both for continuous variables and for multiple categories and dichotomous statistics.

The analysis of these metrics allowed us to determine the contribution of each NOAA model in the prediction, which facilitated the creation of a weighted ensemble. This approach assigns weight to each model based on its performance. With the generated ensemble equations, new predictions were made for the test period, which helped identify areas where the ensemble tended to underestimate or overestimate precipitation. This analysis was crucial for generating a multiplicative correction factor between observed and predicted values, useful for adjusting operational predictions.

As a result, it was observed that, in constructing the ensembles, none of the models stood out significantly for their greater predictive ability over the others, not even the NOAA ensemble, which is the average of all the low-resolution models. Instead, the applied methodology allowed for the identification of the specific contribution of each model to the prediction.

Keywords: climate prediction, models ensemble, canonical correlation analysis, verification of climatological models, monthly climate prediction.



1

Introducción

La predicción climática realizada por el Ideam está basada en los avances en la reducción de escala estadística que se han implementado desde el año 2007, cuando por primera vez se ejecutó el modelo de análisis de correlación canónica utilizando la herramienta desarrollada por el Instituto Internacional de Investigación sobre Clima y Sociedad (IRI, por sus siglas en inglés), conocida como CPT (*Climate Predictability Tool*). Desde entonces, diversas configuraciones para predicciones tanto mensuales como estacionales han sido implementadas por el Grupo de Modelamiento Numérico de Tiempo y Clima, y han alcanzado en la actualidad lo que se denomina predicción por conjuntos o “ensamble”.

Las primeras versiones, al igual que la mayoría de los servicios meteorológicos nacionales, utilizaban campos observados como predictores (por ejemplo, temperatura superficial del mar o variables de circulación atmosférica) (Alfaro, 2007; Amador y Alfaro, 2009; Díaz y Villegas, 2015). El Ideam empleó la temperatura superficial del mar (en adelante, TSM) observada como predictor, y la precipitación medida en estaciones convencionales como la variable a predecir, tal como lo sugirió el Centro Internacional para la Investigación del Fenómeno de El Niño (CIIFEN, 2011). No obstante, los avances realizados por centros internacionales en modelamiento dinámico para pronosticar diversas va-

riables meteorológicas con un horizonte de hasta seis meses, tanto a escala estacional como mensual, junto con el desarrollo de metodologías para integrar datos observados y satelitales de alta resolución espacial para estimar la precipitación, han permitido al Ideam ofrecer hoy predicciones mensuales, no solo probabilísticas, sino también determinísticas. Esto ha sido posible gracias a las mejoras incorporadas en la herramienta CPT, tanto en su componente estadístico como en su soporte lógico (*software*). Las versiones más recientes de CPT, en sus lenguajes bashCPT y pyCPT (Muñoz, 2019), han permitido automatizar procesos en Linux, lo que ha favorecido la ejecución masiva para generar la predicción mensual más probable y ha facilitado la transición de metodologías *FirstGen* a *NextGen*, tal como se explica a continuación:

El término *FirstGen* hace referencia a la primera generación de predicciones iniciadas por el Ideam en 2007, que todavía se mantiene como una alternativa al sistema actual de predicción de precipitación. En este enfoque, se conserva la TSM como variable predictora y la precipitación medida en estaciones meteorológicas como la variable a predecir.

En este caso, la construcción de las series de TSM y precipitación presenta un rezago de un mes. Por ejemplo, para realizar la predicción de enero de 2023, se utiliza la serie de TSM correspondiente a octubre-noviembre

de 1981 a 2022 y la serie de precipitación para el mes de enero de 1982 a 2022. Inicialmente, el modelo estadístico genera relaciones a partir del entrenamiento realizado entre la TSM de octubre-noviembre de 1981 a 2021 y la serie de precipitación para enero de 1982 a 2022. Una vez obtenida la ecuación, esta se aplica a los datos de TSM de octubre-noviembre de 2022 para predecir la precipitación de enero de 2023.

El modelo de predicción utilizado en esta metodología fue el análisis de correlación canónica (Troccoli et al., 2008), con el objetivo de obtener el mejor modelo predictivo mediante una validación cruzada. Para ello, fue esencial determinar el número de modos que se utilizarían tanto para el predictando como para el predictor, así como indicar al modelo que considerara que la precipitación sigue una distribución gamma. Además, se especificó que los resultados de anomalía se calcularan con respecto a la climatología 1991-2020, para que estas predicciones fueran comparables con los resultados de la siguiente generación de pronósticos estacionales, conocidos como *NextGen*.

La metodología *NextGen* representa la nueva generación de predicciones climáticas realizadas por el Ideam bajo la asesoría del IRI. Aunque en su primera versión se aplicó a predicciones estacionales, conforme a lo recomendado por la guía técnica 1246 de la Organización Meteorológica Mundial (OMM, 2019), el Ideam ha estado adaptando esta metodología para predicciones mensuales. Esto ha sido posible gracias a la distribución de datos mensuales de los modelos globales, tanto en términos de climatología como de pronósticos, proporcionados por el *Climate Prediction Center* (CPC) de la NOAA.

Una de las ventajas de realizar predicciones estacionales es que se logra una mayor habilidad predictiva al suavizar el efecto de los eventos extremos causados por fenómenos meteorológicos de escala sinóptica. Sin embargo, esto conlleva la pérdida del detalle mes a mes, especialmente en un país como Colombia, que no está bajo la influencia de estaciones definidas (invierno, primavera, verano, otoño), sino que experimenta tempo-

radas de lluvias y sequías regidas principalmente por la migración de la Zona de Convergencia Intertropical (ZCIT) a lo largo del año. Estas temporadas no coinciden espacialmente en sus distintas épocas. Por ejemplo, en enero, mientras las regiones Caribe, Andina y Orinoquía atraviesan la temporada “seca”, la Amazonía y la región Pacífica experimentan la temporada lluviosa.

Para migrar a metodologías *NextGen*, es importante resaltar que la primera fase consiste en realizar un análisis de habilidad predictiva de las variables meteorológicas que ofrecen los modelos globales, con el fin de usarlas como posibles variables predictoras en un nuevo esquema de predicción. La segunda diferencia clave con la metodología *FirstGen* es que la variable predictor puede ser la misma que la variable a predecir. Es decir, en el caso de la predicción de la precipitación, la variable explicativa (predictora) sería la precipitación proporcionada por cada uno de los modelos globales de baja resolución espacial que forman parte del multiensamble norteamericano (NMME, por sus siglas en inglés). Por su parte, la variable a predecir (predictando) sería la precipitación observada, tomada de estaciones meteorológicas, datos satelitales o reanálisis, tal como lo sugiere la guía 1246 de la OMM sobre Prácticas Operacionales para Pronósticos Estacionales Objetivos.

Con el fin de obtener estos mapas de habilidad predictiva, se realizó un análisis retrospectivo utilizando la herramienta CPT para el período de la climatología de referencia 1991-2020. Esta herramienta divide la serie de datos en dos partes iguales, cada una de 15 años: la serie de tiempo 1991-2005 se utilizó como período de control y la de 2006-2020 como período de prueba. En el período de control, se establecieron relaciones estadísticas entre el predictor y el predictando. Una vez obtenidas estas ecuaciones, se aplicaron al predictor en la serie de prueba para predecir el predictando (es decir, la variable a predecir). Dado que la observación para el período de prueba es conocida, la herramienta CPT es capaz de realizar la validación estadística utilizando diversas métricas. En este análisis, se calcularon las correlaciones de Pearson y Spearman, índice de bondad

(*goodness index*), 2AFC (*Two-alternative forced choice*), sesgo o bias, error cuadrático medio, error absoluto medio, *Gerrity Score*, LEPS y el porcentaje de aciertos de la predicción para los pronósticos a 1, 2, 3, 4, 5 y 6 meses de antelación para un mes determinado.

Es importante destacar que la configuración de estos modelos estadísticos depende de la naturaleza (tipo de distribución) de la variable meteorológica a predecir, así como de la elección de los modos canónicos (modos de covariabilidad) tanto del predictando como del predictor. Esto se hace con el fin de evitar problemas de multicolinealidad (cuando los predictores no son completamente independientes) y multiplicidad (cuando hay demasiados predictores), que además asegura que con el menor número posible de modos canónicos se logre captar la máxima varianza. Al igual que en el enfoque *FirstGen*, el modelo de predicción utilizado es el análisis de correlación canónica, obtenido tras realizar una validación cruzada en la que se indica a la herramienta CPT que la precipitación sigue una distribución gamma durante la ejecución del modelo estadístico.

Cuando se hace referencia a la metodología *NextGen*, generalmente se alude al uso de un conjunto de modelos dinámicos que han sido estadísticamente calibrados y presentados en un formato flexible. El uso de modelos dinámicos implica que se emplean las salidas de varios modelos globales disponibles operativamente, los cuales obtienen actualizaciones periódicas y mejoras constantes. Por otro lado, la calibración estadística se refiere a que, dentro del ensamble, se seleccionan aquellos modelos que, al realizar los mapas de habilidad predictiva, muestran patrones espaciales similares entre la variable predictora y el predictor. Es decir, la distribución espacial de la precipitación del modelo global debe ser similar a la de las observaciones. Este proceso se lleva a cabo revisando los mapas de cargas canónicas en al menos los dos o tres primeros modos canónicos, para garantizar que los modos de variabilidad sean también semejantes. Finalmente, el formato flexible hace referencia a que las últimas versiones de la CPT permi-

ten entregar la función de densidad de probabilidad, lo que posibilita calcular la probabilidad de que ocurra un valor determinístico específico.

Para entender la calibración por patrones espaciales, es útil comprender que el análisis de correlación canónica (ACC) busca patrones espaciales comunes entre dos campos con variabilidad temporal compartida, a través de la maximización de su coeficiente de correlación. Este coeficiente mide el grado de asociación lineal entre los campos, lo que implica que la variación en el predictor influye directamente en la variación del predictando. Generalmente, estos campos corresponden a las componentes principales de los campos originales, lo que permite reducir las dimensiones espaciales utilizando solo los modos de covariabilidad que retienen la mayor parte de la varianza, lo que minimiza el riesgo de incluir señales de ruido en el análisis (Wilks, 2006). Al igual que en el análisis de componentes principales, se obtienen series representativas de cada campo, denominadas “componentes canónicas”, patrones espaciales llamados “mapas canónicos” y un escalar que representa el grado de asociación entre el predictor y el predictando, denominado “correlación canónica” (Muñoz, 2009).

La ejecución de la metodología *NextGen* para realizar predicciones operativas mensuales o estacionales es similar al proceso utilizado para determinar el grado de habilidad predictiva de los modelos globales. La diferencia radica en que, para el período de entrenamiento, se emplean las observaciones y los datos de los modelos globales correspondientes a la climatología de referencia 1991-2020. Una vez obtenidas estas relaciones estadísticas, se aplican a las predicciones generadas por los modelos para obtener resultados en resoluciones espaciales correspondientes a los datos observacionales. Este procedimiento se realiza para cada uno de los modelos que, durante el período de entrenamiento, mostraron patrones similares entre las observaciones y las salidas de los modelos. Finalmente, se realiza un promedio de las salidas de los modelos seleccionados.



Datos utilizados

En cuanto al predictor, el *North American Multi-Model Ensemble* (NMME) es un sistema de pronóstico estacional multimodelo experimental compuesto por un conjunto de modelos acoplados desarrollados en centros de modelado climático de Estados Unidos y Canadá, como la NOAA, NCEP, GFDL, IRI, NCAR, NASA y el CMC. Según Kirtman et al. (2014), el enfoque de conjunto de modelos múltiples ha demostrado ser mucho más eficaz para cuantificar la incertidumbre de predicción debido a las diferencias en la formulación de cada modelo. Además, se ha comprobado que produce, en promedio, una mejor calidad de predicción que cualquier modelo individual. En cuanto a las salidas determinísticas, la OMM (2019) señala que, aunque la media del conjunto se presenta como un valor único y a veces se denomina “determinista”, sigue siendo el resultado de un sistema de predicción probabilístico. Esta media, al ser un promedio de múltiples

realizaciones de pronósticos, no constituye un pronóstico en sí mismo, sino que representa una combinación de varios posibles resultados de pronóstico (ensamble). Este promedio proporciona una indicación sencilla de la amplitud de las anomalías del pronóstico.

Sin embargo, existen algunas desventajas, ya que los métodos empíricos más comunes asumen la estacionariedad del sistema climático y no capturan adecuadamente tendencias y otras variaciones. Además, tienen dificultades para reproducir la varianza observada de los predictandos y, al basarse generalmente en relaciones lineales, presentan limitaciones para representar interacciones no lineales dentro del sistema climático (OMM, 2019).

El conjunto de modelos dinámicos del NMME actualmente disponibles en formato GrADS y CPT se presenta en la Tabla 1.

Tabla 1. Modelos dinámicos del CPC-NOAA

Modelo	Hindcast
CFSv2	1991-2020
CanCM4i (CMC1)	1991-2020
GEM5-NEMO (CMC2)	1991-2020
GFDL	1991-2020
NASA	1991-2020
NCAR-CCSM4	1991-2020
Ensamble Mean	1991-2020

Cada uno de estos modelos cuenta con un conjunto completo de pronósticos retrospectivos (*hindcast*) para el período 1991-2020. Estas predicciones son utilizadas por los centros internacionales para realizar calibraciones e investigaciones. Es importante señalar que en el *Ensemble Mean* (promedio del ensamble), todos los modelos reciben la misma ponderación; es decir, las medias de conjunto de cada modelo se calculan primero y luego se promedian para obtener la media multi-modelo (Kirtman et al., 2014).

En el sitio web del CPC (<https://www.cpc.ncep.noaa.gov/products/international/nmme/nmme.shtml>), las climatologías y las predicciones mensuales con un horizonte de seis meses en baja resolución espacial están disponibles para las siguientes variables meteorológicas:

- La TSM
- La temperatura a 2 metros de altura
- La precipitación

En cuanto al predictando, desde 2020 los datos de precipitación en Colombia se obtienen a partir de los

registros históricos del CHIRPS (Funk et al., 2015), correspondientes al área geográfica situada entre 5° S y 15° N de latitud, y 85° O y 65° O de longitud. Estos datos, con una resolución espacial aproximada de 5,55 km x 5,55 km, han demostrado ser altamente confiables para su uso en Colombia, especialmente a nivel mensual, según los análisis realizados por Urrea et al. (2016) y Martínez y Serna (2018).

Esta confiabilidad hace que los datos de CHIRPS sean preferibles, ya que permiten ofrecer información más precisa sobre todo el territorio nacional en comparación con los análisis basados en los datos provenientes de alrededor de 700 a 800 estaciones meteorológicas, principalmente ubicadas en las regiones Andina y Caribe. Aunque estas estaciones pueden generar buenos resultados a nivel local, al interpolar los datos mediante metodologías de sistemas de información geográfica (SIG) se presenta el fenómeno conocido como “ojo de buey”, que puede afectar la calidad de las predicciones en áreas donde no hay estaciones, como en el sur de la región Caribe y grandes extensiones de las regiones Pacífica, Orinoquía y Amazonía.



Metodología (configuración de la CPT)

En cuanto a la metodología de reducción de escala estadística, la OMM (2019) señala que existen diversos métodos estadísticos con diferentes niveles de complejidad. Los modelos más comunes se basan en regresiones lineales. Los modelos que utilizan directamente el valor del predictor se conocen como modelos de regresión lineal simple, mientras que cuando se emplean varios predictores se les denomina modelos de regresión lineal múltiple. Para reducir los errores de multicolinealidad y los errores de multiplicidad, se suele realizar una reducción dimensional del espacio del predictor mediante el cálculo de funciones empíricas ortogonales (EOF, por sus siglas en inglés) de la variable predictora. Si el modelo de regresión utiliza como predictor las EOF, se denomina regresión de componentes principales (PCR, por sus siglas en inglés).

En el caso de modelos para múltiples localizaciones, los predictandos pueden estar intercorrelacionados, lo que podría llevar a que un enfoque de PCR genere predicciones inconsistentes debido a errores de muestreo al estimar los coeficientes del modelo. En estos casos, se pueden emplear modelos de ACC, que maximizan la correlación entre combinaciones lineales de las EOF del predictando y del predictor seleccionado. Por esta razón, el ACC fue la metodología multivariada utilizada

para generar el nuevo esquema de predicción, tomando como predictores los datos de precipitación dados por los modelos dinámicos del NMME y, como predictando, los datos de precipitación reticulados del CHIRPS.

La OMM (2019) también destaca algunas ventajas de los métodos empíricos, como su bajo requerimiento de recursos computacionales, su facilidad de implementación operativa, su capacidad para estar alineados con las observaciones (ya que incluyen corrección de sesgo, al menos con respecto a los valores medios) y su habilidad para ofrecer predicciones tanto en términos deterministas como probabilísticos.

En cuanto a las posibles variables explicativas para predecir la precipitación en Colombia, es importante destacar que se ha seleccionado un área explicativa para la precipitación, obtenida de cada uno de los modelos globales de la NOAA, tanto para la climatología de referencia como para los datos pronosticados por los siete modelos del NMME. Esta área se encuentra ubicada entre las coordenadas geográficas de 5° S a 15° N de latitud y de 85° O a 65° O de longitud.

Para validar cuáles son los modelos que presentan una mayor habilidad predictiva para la precipitación en Colombia, se realizó un análisis retrospectivo para el período 1991-2020 con los siguientes objetivos:

- Identificar la mejor configuración del modelo dentro del ACC.
- Evaluar la habilidad predictiva de cada uno de los modelos.
- Determinar el peso de los modelos que integrarán el ensamble una vez realizado el análisis anterior.
- Evaluar la predicción dada por el ensamble de modelos para identificar los lugares donde se subestima y sobrestima la precipitación observada (CHIRPS).

En el análisis retrospectivo, la herramienta CPT dividió la serie de 30 años (1991-2020) en dos períodos de 15 años: los primeros 15 años fueron utilizados como período de control y los siguientes 15 años como período de prueba para realizar la predicción. Inicialmente, se configuró el modelo de ACC con cinco modos de covariabilidad tanto para el predictor como para el predictando, y se le indicó a la herramienta CPT que tuviera en cuenta que la precipitación sigue una distribución gamma. Con esta configuración, se revisó el diagrama de *Scree Plot* y se observó que, en general, los primeros diez modos de covariabilidad tanto del predictando (la precipitación dada por cada uno de los modelos

del NMME) como del predictor (precipitación CHIRPS) retienen aproximadamente el 80 % de la varianza observada. Además, se evaluó su habilidad predictiva utilizando diversas métricas estadísticas, las cuales, según el *World Climate Research Project* (WCRP), se clasifican de la siguiente manera:

Estadísticos inferenciales

- Correlación de Pearson
- Correlación de Spearman
- Índice de bondad

Estadísticos para variables continuas

- Error medio absoluto
- Error cuadrático medio
- Error lineal en la probabilidad (LEPS)

Estadísticos para múltiples categorías

- Prueba de selección forzada 2AFC
- *Gerrity Score*

Estadísticos dicotómicos

- *Hit score*

Estadísticos inferenciales

Correlación de Pearson: es una medida estadística que evalúa la relación lineal entre dos variables continuas. Su valor oscila entre -1 y +1, donde:

- +1 indica una correlación perfecta positiva: ambas variables se mueven en la misma dirección de forma proporcional.

- -1 indica una correlación perfecta negativa: ambas variables se mueven en direcciones opuestas de forma proporcional.
- 0 indica que no hay ninguna relación lineal entre las variables.

$$r = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}}$$

Donde x_i y y_i son los valores de las dos variables, y \bar{x} y \bar{y} son sus medias.

Correlación de Spearman: es una medida estadística que evalúa la relación entre dos variables utilizando rangos en lugar de valores numéricos originales. Es útil cuando los datos no siguen una distribución normal o cuando la relación entre las variables no es lineal, ya que mide la asociación monótona entre las dos variables (es decir, si una variable tiende a aumentar o disminuir de manera consistente a medida que lo hace la otra, sin necesidad de que la relación sea lineal).

Características clave:

- **No lineal:** no requiere que la relación entre las variables sea lineal. Solo requiere que la relación sea

monótona, lo que significa que las variables tienden a moverse en la misma dirección (o en direcciones opuestas) de manera consistente.

- **Rangos:** en lugar de usar los valores numéricos directos, utiliza rangos, lo que la hace menos sensible a los valores atípicos (*outliers*) que pueden distorsionar la correlación.
- **Rango de valores:** el coeficiente de correlación de Spearman (ρ) varía entre -1 y +1, de manera similar a la correlación de Pearson:
 - +1: Correlación perfecta positiva.
 - -1: Correlación perfecta negativa.
 - 0: No hay correlación monótona.

$$\rho = 1 - \frac{6 \sum d_i^2}{N(N^2 - 1)}$$

Donde d_i es la diferencia entre los rangos de cada par de variables, y N es el número total de pares.

Índice de bondad: es una métrica estadística que se utiliza para evaluar la capacidad de un modelo de predicción para ajustarse a los datos observados. En otras palabras, mide qué tan bien el modelo es capaz de replicar o predecir los valores observados, evaluando la relación entre las predicciones del modelo y los datos reales, mediante la validación cruzada de las series de datos disponibles.

Cuando se emplean coeficientes de correlación como Pearson o Spearman, es importante recordar que un promedio simple de estas correlaciones no siempre proporciona un valor matemáticamente consistente, especialmente cuando las correlaciones son extremas (es decir, valores de +1 o -1). En estos casos, para realizar una evaluación más precisa y estadísticamente válida, se recomienda aplicar la transformación de Fisher.

Estadísticos para variables continuas

MAE (Error Medio Absoluto): es una métrica estadística utilizada para medir el rendimiento de un modelo de predicción. Representa el promedio de las diferencias absolutas entre los valores predichos y los valores observados (reales). Esta métrica es muy útil

cuando se desea evaluar qué tan cerca están las predicciones del modelo de los valores reales, sin importar la dirección del error (es decir, si la predicción es mayor o menor que el valor real).

La ecuación para calcular el MAE es

$$MAE = \frac{1}{n} \sum_{i=1}^N |\hat{y}_i - y_i|$$

Donde n es el número de datos, y_i son los valores reales y \hat{y}_i son los valores predichos por el modelo.

RMSE (Error Cuadrático Medio): es una métrica estadística ampliamente utilizada para evaluar la precisión de un modelo de predicción. El RMSE mide la diferencia promedio entre los valores predichos por el

modelo y los valores observados (reales), pero a diferencia del MAE, el RMSE penaliza más los errores grandes al elevar al cuadrado las diferencias antes de promediarlas.

La ecuación para calcular el RMSE es

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2}$$

Donde n es el número de datos, y_i son los valores reales y \hat{y}_i son los valores predichos por el modelo.

LEPS (Error Lineal en la Probabilidad): es una métrica estadística utilizada para evaluar la precisión de los modelos de predicción, especialmente en la predicción de variables probabilísticas o de eventos binarios, como la ocurrencia o no de un fenómeno, a partir de probabilidades. El LEPS mide el error en términos de las probabilidades predichas frente a las observadas, pero lo hace en el espacio de probabilidades (es decir, considerando las probabilidades predichas y las observadas

en términos lineales). Es una forma de comparar qué tan bien las probabilidades predichas se corresponden con las probabilidades observadas de un evento. Es particularmente útil en situaciones donde no solo se desea saber si la predicción es correcta, sino también qué tan bien el modelo puede estimar la probabilidad de un evento. Por ejemplo, en la predicción de precipitaciones, donde el modelo predice una probabilidad de lluvia y la observación es binaria (lluvia/no lluvia).

La ecuación para calcular el LEPS es

$$LEPS = \frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2$$

Donde P_i es la probabilidad predicha para el i -ésimo evento (por ejemplo, la probabilidad de lluvia predicha por el modelo), O_i es el valor observado para el i -ésimo evento y n es el número total de observaciones. El valor observado es 1 si el evento ocurrió (por ejemplo, lluvia) y 0 si el evento no ocurrió (por ejemplo, no lluvia)

Estadísticos para múltiples categorías

2AFC (Prueba de selección forzada): mide la probabilidad de discriminar correctamente una observación perteneciente a una categoría superior frente a otra de una categoría inferior (por ejemplo, una observación “por encima de lo normal” frente a una “normal”), basándose en las predicciones expresadas en

forma determinista (es decir, utilizando los valores específicos del modelo, y no las probabilidades asociadas a estos). En resumen, el 2AFC evalúa la capacidad de un modelo para distinguir correctamente entre dos categorías de observaciones, como diferenciar un evento

“por encima de lo normal” de uno “normal”, a partir de los valores pronosticados por el modelo.

Gerrity Score: es una métrica estadística utilizada para evaluar la calidad de las predicciones en meteorología y climatología, particularmente en modelos de predicción probabilística. Este índice cuantifica la habilidad de un modelo para predecir correctamente tanto la magnitud como la dirección de los eventos climáticos (como precipitaciones o temperaturas), en comparación con las observaciones reales. El *Gerrity Score* es especialmente útil, porque tiene en cuenta no solo los errores en la magnitud de la predicción, sino también la capacidad del modelo para asignar probabilidad-

des adecuadas a los diferentes resultados posibles. De esta manera, no solo se evalúa si el modelo predice correctamente si ocurrirá un evento (por ejemplo, lluvia), sino también cuán confiables son las probabilidades asignadas a cada tipo de evento.

En general, esta métrica se calcula mediante un sistema que compara las predicciones probabilísticas del modelo con las observaciones, y evalúa el grado de ajuste de estas predicciones en términos de magnitudes y probabilidades. La puntuación más alta indica una mejor habilidad predictiva, y suele utilizarse junto con otras métricas para dar con una evaluación completa del desempeño del modelo.

Estadísticos Dicotómicos

Hit Score (Tasa de aciertos): mide la proporción de veces que el modelo predice correctamente un evento.

$$\text{Hit rate} = \frac{\text{Aciertos}}{\text{Total de Observaciones}}$$

Los estadísticos previamente mencionados se calcularon utilizando la resolución espacial de los datos del CHIRPS. Sin embargo, para obtener una representación nacional del rendimiento predictivo, dichos datos, que se distribuyen espacialmente, fueron promediados para cada una de las 12 condiciones iniciales, considerando un horizonte de predicción de seis meses. Este procedimiento tuvo como objetivo cuantificar, a nivel nacional,

el aporte de cada modelo dentro del ensamble ponderado (en lugar de un promedio simple).

Finalmente, se aplicó un factor de cambio multiplicativo a cada punto de la retícula, para estimar las áreas del país donde el ensamble ponderado tendía a sobreestimar o subestimar la predicción de precipitación. Este análisis se llevó a cabo de la siguiente manera:

$$\alpha Y_{\text{observado}} = \alpha Y_{\text{predicción}}$$

$$\alpha = \frac{Y_{\text{predicción}}}{Y_{\text{observado}}}$$

Donde α (adimensional) es el factor de cambio multiplicativo, $Y_{\text{observado}}$ corresponde a los datos observados (CHIRPS) y $Y_{\text{predicción}}$ representa los datos de predicción generados por el ensamble ponderado. De esta forma, si el valor de α es mayor que 1 ($\alpha > 1$), significa que el ensamble ponderado sobreestima la

precipitación observada. Por el contrario, si α es menor que 1 ($\alpha < 1$), indica que el ensamble subestima la observación. La obtención de estos coeficientes es crucial para realizar ajustes y corregir las predicciones generadas por el ensamble ponderado, lo que contribuye a una mayor precisión en los resultados de las predicciones.



4

Discusión y resultados

Es relevante destacar que, para la presentación de los resultados, se realizó un ranking de los modelos con base en su desempeño según las métricas estadísticas previamente descritas, clasificándolos de mayor a menor (del 7 al 1). Como ejemplo, en la Tabla 2 se muestra el Índice de bondad (*goodness index*) obtenido por cada uno de los modelos al utilizar condiciones iniciales de enero para la predicción de febrero. El modelo de la NASA alcanzó el mejor índice de bondad (calificación 7), seguido por CFSv2 (6), y así sucesivamente hasta llegar a CanCM4i, que obtuvo el valor más bajo de esta métrica (1).

Una vez que se calcularon estos valores para cada indicador estadístico, se sumaron horizontalmente por cada modelo. El resultado de cada uno de ellos se observa en la columna “Total” de la tabla. Para determinar el

peso de cada modelo dentro del ensamble final, se sumaron verticalmente los valores obtenidos en dicha columna, lo que resultó en un total de 252. A partir de este total, se aplicó una regla de tres para calcular el porcentaje de contribución de cada modelo al ensamble final. Por ejemplo, el modelo *ENSAMBLE MEAN*, que obtuvo 46 puntos en la columna “Total”, representa aproximadamente el 18,3 % (columna “Porcentaje”) de 252, que es el total del ensamble. Estas contribuciones porcentuales se pueden apreciar mejor en el Anexo 1.

Finalmente, la columna “Coeficientes” muestra los valores normalizados de cada modelo, ajustados a un total de 1. Con estos valores se construyó la siguiente ecuación para realizar la predicción del mes de febrero (*PFEB*), utilizando como insumo las condiciones iniciales de los modelos para el mes de enero:

$$PFEB = 0.183 * ENSAMBLE MEAN + 0.183 * NCAR-CCSM4 + 0.147 * NASA + 0.175 * GFDL + 0.123 * GEM5-NEMO + 0.063 * CanCM4i + 0.127 * CFSv2$$

Es importante señalar que, en la construcción de los ensambles, ningún modelo se destacó significativamente sobre los demás por ofrecer una mayor habilidad predictiva, ni siquiera el mismo ensamble en su conjunto. Más bien, la metodología aplicada permitió determinar la contribución específica de cada modelo para la realización de la predicción. Desde la Tabla 2 hasta la Tabla 13 se presenta la ecuación de predicción obtenida para las 12 condiciones iniciales, considerando un horizonte de predicción de seis meses. Sin embargo, el orden de los modelos según su capacidad predictiva fue el siguiente: CFSv2, GFDL, GEM5.2-NEMO, NCAR-CCSM4, CanESM5, NASA y NMME.

Aunque este análisis se presenta a nivel nacional, los resultados también se encuentran disponibles para cada uno de los puntos de retícula proporcionados por CHIRPS. Además, con base en los errores observados entre las predicciones generadas por las ecuaciones de ensamble y las observaciones reales durante el período 1991-2020, se identificaron zonas del país donde los modelos tienden a sobrestimar o subestimar la precipitación. Estas diferencias entre lo estimado por el ensamble y lo registrado por las estaciones se muestran claramente en las Figuras del 1 al 12. El análisis del factor de cambio indica, en términos generales, que dichos errores varían según las condiciones iniciales a lo largo de los seis meses de predicción.

Tabla 2. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de enero

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Febrero	NMME	4	6	6	6	1	5	7	5	6	46	18,3	NMME	0,182539683
	NCAR_CCSM4	5	5	5	7	2	6	5	6	5	46	18,3	NCAR_CCSM4	0,182539683
	NASA	7	3	4	3	5	4	3	4	4	37	14,7	NASA	0,146825397
	GFDL	3	7	7	5	3	3	6	3	7	44	17,5	GFDL	0,174603175
	CMC2	2	2	1	1	7	7	2	7	2	31	12,3	CMC2	0,123015873
	CMC1	1	1	2	2	6	1	1	1	1	16	6,3	CMC1	0,063492063
	CFSV2	6	4	3	4	4	2	4	2	3	32	12,7	CFSV2	0,126984127
Marzo	NMME	2	5	7	5	1	6	6	5	6	43	17,1	NMME	0,170634921
	NCAR_CCSM4	5	6	4	7	6	7	3	7	5	50	19,8	NCAR_CCSM4	0,198412698
	NASA	3	1	3	1	3	5	1	6	2	25	9,9	NASA	0,099206349
	GFDL	7	7	6	4	4	3	7	3	7	48	19,0	GFDL	0,19047619
	CMC2	6	4	5	6	2	2	5	2	4	36	14,3	CMC2	0,142857143
	CMC1	1	2	2	3	7	1	4	1	1	22	8,7	CMC1	0,087301587
	CFSV2	4	3	1	2	5	4	2	4	3	28	11,1	CFSV2	0,111111111
Abril	NMME	6	6	4	4	4	2	6	2	6	40	15,9	NMME	0,158730159
	NCAR_CCSM4	1	4	7	6	2	4	4	3	5	36	14,3	NCAR_CCSM4	0,142857143
	NASA	4	3	2	2	6	3	5	5	3	33	13,1	NASA	0,130952381
	GFDL	2	1	1	1	7	1	1	1	1	16	6,3	GFDL	0,063492063
	CMC2	5	5	3	5	3	5	3	6	4	39	15,5	CMC2	0,154761905
	CMC1	3	2	6	7	1	7	2	4	2	34	13,5	CMC1	0,134920635
	CFSV2	7	7	5	3	5	6	7	7	7	54	21,4	CFSV2	0,214285714
Mayo	NMME	3	4	4	4	4	1	4	1	4	29	11,5	NMME	0,115079365
	NCAR_CCSM4	6	6	3	3	5	4	5	4	6	42	16,7	NCAR_CCSM4	0,166666667
	NASA	2	3	6	6	2	5	3	5	3	35	13,9	NASA	0,138888889
	GFDL	4	5	5	5	3	6	6	6	5	45	17,9	GFDL	0,178571429
	CMC2	1	1	1	1	6	3	1	3	1	18	7,1	CMC2	0,071428571
	CMC1	5	2	2	2	7	2	2	2	2	26	10,3	CMC1	0,103174603
	CFSV2	7	7	7	7	1	7	7	7	7	57	22,6	CFSV2	0,226190476
Junio	NMME	4	4	3	2	6	2	3	3	4	31	12,3	NMME	0,123015873
	NCAR_CCSM4	3	6	7	7	4	1	7	1	7	43	17,1	NCAR_CCSM4	0,170634921
	NASA	5	2	2	3	5	6	2	6	2	33	13,1	NASA	0,130952381
	GFDL	1	1	1	1	7	4	1	5	1	22	8,7	GFDL	0,087301587
	CMC2	7	3	4	5	1	5	4	4	3	36	14,3	CMC2	0,142857143
	CMC1	6	7	6	4	2	7	6	7	6	51	20,2	CMC1	0,202380952
	CFSV2	2	5	5	6	3	3	5	2	5	36	14,3	CFSV2	0,142857143
Julio	NMME	6	6	6	5	3	2	7	2	6	43	17,1	NMME	0,170634921
	NCAR_CCSM4	2	4	2	1	7	1	4	1	4	26	10,3	NCAR_CCSM4	0,103174603
	NASA	7	5	5	6	2	7	5	7	5	49	19,4	NASA	0,194444444
	GFDL	4	2	3	4	5	6	2	6	2	34	13,5	GFDL	0,134920635
	CMC2	5	7	7	7	1	5	6	4	7	49	19,4	CMC2	0,194444444
	CMC1	3	3	4	3	4	4	3	5	3	32	12,7	CMC1	0,126984127
	CFSV2	1	1	1	2	6	3	1	3	1	19	7,5	CFSV2	0,075396825

Tabla 3. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de febrero

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Marzo	NMME	3	5	5	4	3	3	7	3	6	39	15,5	NMME	0,154761905
	NCAR_CCSM4	7	3	2	1	6	7	2	7	3	38	15,1	NCAR_CCSM4	0,150793651
	NASA	2	1	3	5	4	4	1	5	1	26	10,3	NASA	0,103174603
	GFDL	5	2	7	7	2	5	5	4	2	39	15,5	GFDL	0,154761905
	CMC2	4	4	4	3	5	2	4	2	4	32	12,7	CMC2	0,126984127
	CMC1	1	6	1	2	7	1	3	1	5	27	10,7	CMC1	0,107142857
CFSV2	6	7	6	6	1	6	6	6	6	7	51	20,2	CFSV2	0,202380952

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Abril	NMME	5	1	2	2	6	4	1	4	1	26	10,3	NMME	0,103174603
	NCAR_CCSM4	7	6	5	5	3	6	5	2	6	45	17,9	NCAR_CCSM4	0,178571429
	NASA	6	3	4	3	5	2	4	6	3	36	14,3	NASA	0,142857143
	GFDL	4	7	7	7	2	5	7	5	7	51	20,2	GFDL	0,202380952
	CMC2	3	4	6	6	1	7	6	7	4	44	17,5	CMC2	0,174603175
	CMC1	2	5	3	4	4	1	3	1	5	28	11,1	CMC1	0,111111111
CFSV2	1	2	1	1	7	3	2	3	2	22	8,7	CFSV2	0,087301587	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Mayo	NMME	4	5	6	5	3	2	6	2	6	39	15,5	NMME	0,154761905
	NCAR_CCSM4	7	6	5	6	2	5	5	4	5	45	17,9	NCAR_CCSM4	0,178571429
	NASA	5	3	4	3	5	6	4	6	4	40	15,9	NASA	0,158730159
	GFDL	1	2	1	1	7	1	2	1	2	18	7,1	GFDL	0,071428571
	CMC2	6	7	7	7	1	7	7	7	7	56	22,2	CMC2	0,222222222
	CMC1	3	1	2	2	6	4	1	5	1	25	9,9	CMC1	0,099206349
CFSV2	2	4	3	4	4	3	3	3	3	29	11,5	CFSV2	0,115079365	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Junio	NMME	4	3	3	6	4	1	3	1	3	28	11,1	NMME	0,111111111
	NCAR_CCSM4	6	1	1	3	6	3	1	3	2	26	10,3	NCAR_CCSM4	0,103174603
	NASA	3	6	5	4	5	6	6	7	6	48	19,0	NASA	0,19047619
	GFDL	2	5	2	2	3	7	5	6	5	37	14,7	GFDL	0,146825397
	CMC2	5	2	4	1	7	2	2	2	1	26	10,3	CMC2	0,103174603
	CMC1	7	7	7	5	1	4	7	4	7	49	19,4	CMC1	0,194444444
CFSV2	1	4	6	7	2	5	4	5	4	38	15,1	CFSV2	0,150793651	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Julio	NMME	6	7	7	7	1	5	7	4	7	51	20,2	NMME	0,202380952
	NCAR_CCSM4	3	5	3	5	5	2	5	2	2	32	12,7	NCAR_CCSM4	0,126984127
	NASA	2	4	4	3	4	7	4	7	5	40	15,9	NASA	0,158730159
	GFDL	7	6	6	6	2	6	6	6	6	51	20,2	GFDL	0,202380952
	CMC2	5	3	2	2	6	1	3	1	4	27	10,7	CMC2	0,107142857
	CMC1	4	2	5	4	3	3	2	3	3	29	11,5	CMC1	0,115079365
CFSV2	1	1	1	1	7	4	1	5	1	22	8,7	CFSV2	0,087301587	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Agosto	NMME	6	5	6	6	2	5	6	5	5	46	18,3	NMME	0,182539683
	NCAR_CCSM4	7	6	5	5	3	6	5	6	6	49	19,4	NCAR_CCSM4	0,194444444
	NASA	2	3	3	2	6	4	3	4	3	30	11,9	NASA	0,119047619
	GFDL	5	7	7	7	1	7	7	7	7	55	21,8	GFDL	0,218253968
	CMC2	1	1	1	1	7	2	2	2	2	19	7,5	CMC2	0,075396825
	CMC1	3	4	4	4	4	3	4	3	4	33	13,1	CMC1	0,130952381
CFSV2	4	2	2	3	5	1	1	1	1	20	7,9	CFSV2	0,079365079	

Tabla 4. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de marzo

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Abril	NMME	5	4	3	2	5	5	6	6	5	41	16,3	NMME	0,162698413
	NCAR_CCSM4	3	3	2	1	6	2	3	2	3	25	9,9	NCAR_CCSM4	0,099206349
	NASA	2	5	5	4	4	4	4	3	4	35	13,9	NASA	0,138888889
	GFDL	1	1	1	3	7	1	1	1	1	17	6,7	GFDL	0,067460317
	CMC2	6	2	4	5	1	7	2	7	2	36	14,3	CMC2	0,142857143
	CMC1	4	6	6	6	2	6	5	5	6	46	18,3	CMC1	0,182539683
	CFSV2	7	7	7	7	3	3	7	4	7	52	20,6	CFSV2	0,206349206
Mayo	NMME	3	4	5	5	4	3	5	3	4	36	14,3	NMME	0,142857143
	NCAR_CCSM4	1	6	6	4	3	4	6	5	6	41	16,3	NCAR_CCSM4	0,162698413
	NASA	2	1	1	1	7	2	1	2	1	18	7,1	NASA	0,071428571
	GFDL	4	2	2	2	6	1	3	1	2	23	9,1	GFDL	0,091269841
	CMC2	6	7	4	7	1	6	7	6	7	51	20,2	CMC2	0,202380952
	CMC1	5	3	3	3	5	5	2	7	3	36	14,3	CMC1	0,142857143
	CFSV2	7	5	7	6	2	7	4	4	5	47	18,7	CFSV2	0,186507937
Junio	NMME	7	4	5	6	2	7	4	7	5	47	18,7	NMME	0,186507937
	NCAR_CCSM4	5	5	4	2	5	1	5	1	4	32	12,7	NCAR_CCSM4	0,126984127
	NASA	2	6	6	7	3	6	6	6	7	49	19,4	NASA	0,194444444
	GFDL	4	1	1	1	7	2	2	2	1	21	8,3	GFDL	0,083333333
	CMC2	6	3	3	3	6	3	3	3	3	33	13,1	CMC2	0,130952381
	CMC1	3	7	7	5	1	5	7	5	6	46	18,3	CMC1	0,182539683
	CFSV2	1	2	2	4	4	4	1	4	2	24	9,5	CFSV2	0,095238095
Julio	NMME	5	5	6	6	1	1	5	1	6	36	14,3	NMME	0,142857143
	NCAR_CCSM4	4	4	3	3	5	2	4	3	4	32	12,7	NCAR_CCSM4	0,126984127
	NASA	6	7	5	5	3	4	7	6	7	50	19,8	NASA	0,198412698
	GFDL	7	6	7	7	2	5	6	5	5	50	19,8	GFDL	0,198412698
	CMC2	3	3	2	4	4	7	3	4	3	33	13,1	CMC2	0,130952381
	CMC1	1	2	4	2	6	3	2	2	2	24	9,5	CMC1	0,095238095
	CFSV2	2	1	1	1	7	6	1	7	1	27	10,7	CFSV2	0,107142857
Agosto	NMME	6	5	5	5	2	5	4	5	5	42	16,7	NMME	0,166666667
	NCAR_CCSM4	7	4	4	4	4	1	5	3	4	36	14,3	NCAR_CCSM4	0,142857143
	NASA	3	2	2	3	6	4	2	2	3	27	10,7	NASA	0,107142857
	GFDL	4	7	7	7	1	7	7	7	7	54	21,4	GFDL	0,214285714
	CMC2	1	1	1	1	7	3	1	4	1	20	7,9	CMC2	0,079365079
	CMC1	2	3	3	2	5	6	3	6	2	32	12,7	CMC1	0,126984127
	CFSV2	5	6	6	6	3	2	6	1	6	41	16,3	CFSV2	0,162698413
Septiembre	NMME	4	5	4	5	4	4	5	4	5	40	15,9	NMME	0,158730159
	NCAR_CCSM4	6	6	6	4	5	3	6	3	6	45	17,9	NCAR_CCSM4	0,178571429
	NASA	1	2	2	2	6	5	2	5	2	27	10,7	NASA	0,107142857
	GFDL	7	7	7	7	1	7	7	7	7	57	22,6	GFDL	0,226190476
	CMC2	5	3	3	3	3	2	4	1	4	28	11,1	CMC2	0,111111111
	CMC1	3	4	5	6	2	6	3	6	3	38	15,1	CMC1	0,150793651
	CFSV2	2	1	1	1	7	1	1	2	1	17	6,7	CFSV2	0,067460317

Tabla 5. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de abril

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Mayo	NMME	4	4	4	3	5	2	2	1	4	29	11,5	NMME	0,115079365
	NCAR_CCSM4	1	2	3	2	6	4	4	4	2	28	11,1	NCAR_CCSM4	0,111111111
	NASA	3	1	1	1	7	1	1	2	1	18	7,1	NASA	0,071428571
	GFDL	5	6	5	6	2	5	6	6	6	47	18,7	GFDL	0,186507937
	CMC2	7	3	2	4	4	3	3	3	3	32	12,7	CMC2	0,126984127
	CMC1	6	7	7	7	1	7	7	5	7	54	21,4	CMC1	0,214285714
	CFSV2	2	5	6	5	3	6	5	7	5	44	17,5	CFSV2	0,174603175
Junio	NMME	4	2	2	6	4	3	2	3	2	28	11,1	NMME	0,111111111
	NCAR_CCSM4	7	3	3	3	3	5	4	4	5	37	14,7	NCAR_CCSM4	0,146825397
	NASA	1	5	4	5	7	2	3	2	4	33	13,1	NASA	0,130952381
	GFDL	3	7	7	7	1	7	7	6	7	52	20,6	GFDL	0,206349206
	CMC2	5	4	5	2	2	6	5	5	3	37	14,7	CMC2	0,146825397
	CMC1	2	6	6	1	6	4	6	7	6	44	17,5	CMC1	0,174603175
	CFSV2	6	1	1	4	5	1	1	1	1	21	8,3	CFSV2	0,083333333
Julio	NMME	5	4	3	3	4	1	3	1	4	28	11,1	NMME	0,111111111
	NCAR_CCSM4	6	7	6	6	2	6	7	7	7	54	21,4	NCAR_CCSM4	0,214285714
	NASA	1	6	5	4	5	5	6	6	6	44	17,5	NASA	0,174603175
	GFDL	7	5	7	7	1	7	5	5	5	49	19,4	GFDL	0,194444444
	CMC2	4	3	1	2	7	4	1	3	3	28	11,1	CMC2	0,111111111
	CMC1	2	1	2	1	6	2	4	2	2	22	8,7	CMC1	0,087301587
	CFSV2	3	2	4	5	3	3	2	4	1	27	10,7	CFSV2	0,107142857
Agosto	NMME	5	4	6	6	2	6	7	5	5	46	18,3	NMME	0,182539683
	NCAR_CCSM4	7	5	4	4	4	5	6	6	7	48	19,0	NCAR_CCSM4	0,19047619
	NASA	1	1	1	1	7	1	1	2	1	16	6,3	NASA	0,063492063
	GFDL	6	7	7	5	3	3	5	3	6	45	17,9	GFDL	0,178571429
	CMC2	2	3	3	2	6	7	3	7	2	35	13,9	CMC2	0,138888889
	CMC1	4	2	2	3	5	4	2	4	3	29	11,5	CMC1	0,115079365
	CFSV2	3	6	5	7	1	2	4	1	4	33	13,1	CFSV2	0,130952381
Septiembre	NMME	5	6	5	5	3	3	6	3	6	42	16,7	NMME	0,166666667
	NCAR_CCSM4	1	3	1	2	7	1	3	1	3	22	8,7	NCAR_CCSM4	0,087301587
	NASA	4	1	2	1	6	2	1	2	1	20	7,9	NASA	0,079365079
	GFDL	7	5	6	6	2	5	5	5	5	46	18,3	GFDL	0,182539683
	CMC2	6	7	7	7	1	7	7	7	7	56	22,2	CMC2	0,222222222
	CMC1	3	2	3	3	5	4	2	4	2	28	11,1	CMC1	0,111111111
	CFSV2	2	4	4	4	4	4	6	4	6	38	15,1	CFSV2	0,150793651
Octubre	NMME	5	4	3	3	6	2	4	2	4	33	13,1	NMME	0,130952381
	NCAR_CCSM4	2	2	2	2	5	1	2	1	2	19	7,5	NCAR_CCSM4	0,075396825
	NASA	1	1	1	1	7	5	1	5	1	23	9,1	NASA	0,091269841
	GFDL	4	3	4	5	4	3	3	4	3	33	13,1	GFDL	0,130952381
	CMC2	6	5	6	6	2	6	5	6	5	47	18,7	CMC2	0,186507937
	CMC1	7	6	5	4	3	7	7	7	6	52	20,6	CMC1	0,206349206
	CFSV2	3	7	7	7	1	4	6	3	7	45	17,9	CFSV2	0,178571429

Tabla 6. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de mayo

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Junio	NMME	7	5	7	7	2	2	6	2	5	43	17,1	NMME	0,170634921
	NCAR_CCSM4	1	2	3	1	7	4	4	4	3	29	11,5	NCAR_CCSM4	0,115079365
	NASA	6	7	4	5	1	6	7	6	7	49	19,4	NASA	0,194444444
	GFDL	3	1	1	3	3	7	1	7	1	27	10,7	GFDL	0,107142857
	CMC2	4	4	5	6	6	3	3	3	4	38	15,1	CMC2	0,150793651
	CMC1	2	6	6	4	4	1	5	1	6	35	13,9	CMC1	0,138888889
	CFSV2	5	3	2	2	5	5	2	5	2	31	12,3	CFSV2	0,123015873
Julio	NMME	3	2	1	2	5	3	2	2	2	22	8,7	NMME	0,087301587
	NCAR_CCSM4	2	3	3	1	7	2	4	4	3	29	11,5	NCAR_CCSM4	0,115079365
	NASA	1	4	4	5	3	7	3	7	4	38	15,1	NASA	0,150793651
	GFDL	5	5	6	7	1	5	5	5	6	45	17,9	GFDL	0,178571429
	CMC2	4	7	5	4	4	4	6	3	7	44	17,5	CMC2	0,174603175
	CMC1	6	1	2	6	6	1	1	1	1	25	9,9	CMC1	0,099206349
	CFSV2	7	6	7	3	2	6	7	6	5	49	19,4	CFSV2	0,194444444
Agosto	NMME	6	1	3	2	6	3	4	4	3	32	12,7	NMME	0,126984127
	NCAR_CCSM4	2	3	2	3	5	2	2	2	2	23	9,1	NCAR_CCSM4	0,091269841
	NASA	4	4	5	4	3	7	3	5	4	39	15,5	NASA	0,154761905
	GFDL	1	5	4	6	2	5	5	6	5	39	15,5	GFDL	0,154761905
	CMC2	3	2	1	1	7	4	1	3	1	23	9,1	CMC2	0,091269841
	CMC1	7	6	6	5	4	1	7	1	6	43	17,1	CMC1	0,170634921
	CFSV2	5	7	7	7	1	6	6	7	7	53	21,0	CFSV2	0,21031746
Septiembre	NMME	4	6	6	6	1	3	6	1	7	40	15,9	NMME	0,158730159
	NCAR_CCSM4	6	7	7	7	2	7	7	7	6	56	22,2	NCAR_CCSM4	0,222222222
	NASA	1	1	2	2	7	2	1	2	1	19	7,5	NASA	0,075396825
	GFDL	3	4	4	4	4	1	5	3	4	32	12,7	GFDL	0,126984127
	CMC2	5	2	1	1	6	5	4	5	2	31	12,3	CMC2	0,123015873
	CMC1	7	3	3	3	3	4	2	4	3	32	12,7	CMC1	0,126984127
	CFSV2	2	5	5	5	5	6	3	6	5	42	16,7	CFSV2	0,166666667
Octubre	NMME	5	5	2	3	5	1	4	1	5	31	12,3	NMME	0,123015873
	NCAR_CCSM4	2	1	1	2	7	2	1	2	1	19	7,5	NCAR_CCSM4	0,075396825
	NASA	1	3	4	1	6	3	3	3	3	27	10,7	NASA	0,107142857
	GFDL	3	4	5	5	3	5	5	5	4	39	15,5	GFDL	0,154761905
	CMC2	7	7	7	7	1	7	7	7	7	57	22,6	CMC2	0,226190476
	CMC1	6	2	3	4	4	4	2	4	2	31	12,3	CMC1	0,123015873
	CFSV2	4	6	6	6	2	6	6	6	6	48	19,0	CFSV2	0,19047619
Noviembre	NMME	3	6	5	5	3	5	6	4	6	43	17,1	NMME	0,170634921
	NCAR_CCSM4	4	1	1	2	5	1	1	2	1	18	7,1	NCAR_CCSM4	0,071428571
	NASA	1	5	6	6	2	7	5	7	5	44	17,5	NASA	0,174603175
	GFDL	6	2	3	4	4	4	2	5	3	33	13,1	GFDL	0,130952381
	CMC2	5	3	2	1	6	3	3	1	2	26	10,3	CMC2	0,103174603
	CMC1	2	4	4	3	7	2	4	3	4	33	13,1	CMC1	0,130952381
	CFSV2	7	7	7	7	1	6	7	6	7	55	21,8	CFSV2	0,218253968

Tabla 7. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de junio

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Julio	NMME	4	1	2	4	7	2	3	2	1	26	10,3	NMME	0,103174603
	NCAR_CCSM4	3	7	5	1	5	1	7	1	7	37	14,7	NCAR_CCSM4	0,146825397
	NASA	1	6	4	2	4	5	6	5	6	39	15,5	NASA	0,154761905
	GFDL	7	3	3	5	3	7	2	7	3	40	15,9	GFDL	0,158730159
	CMC2	5	5	6	7	1	6	5	6	5	46	18,3	CMC2	0,182539683
	CMC1	2	4	7	6	2	4	4	4	4	37	14,7	CMC1	0,146825397
CFSV2	6	2	1	3	6	3	1	3	2	27	10,7	CFSV2	0,107142857	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Agosto	NMME	5	7	7	6	1	2	7	2	7	44	17,5	NMME	0,174603175
	NCAR_CCSM4	6	6	5	5	2	1	2	1	6	34	13,5	NCAR_CCSM4	0,134920635
	NASA	1	5	6	7	3	7	6	7	5	47	18,7	NASA	0,186507937
	GFDL	4	2	1	2	5	3	3	4	3	27	10,7	GFDL	0,107142857
	CMC2	3	3	2	1	7	5	1	3	2	27	10,7	CMC2	0,107142857
	CMC1	7	4	4	4	4	6	5	6	4	44	17,5	CMC1	0,174603175
CFSV2	2	1	3	3	6	4	4	5	1	29	11,5	CFSV2	0,115079365	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Septiembre	NMME	1	2	3	1	7	2	3	2	2	23	9,1	NMME	0,091269841
	NCAR_CCSM4	2	6	6	2	6	1	1	1	6	31	12,3	NCAR_CCSM4	0,123015873
	NASA	3	7	7	6	2	7	7	7	7	53	21,0	NASA	0,21031746
	GFDL	6	4	5	7	1	5	5	5	4	42	16,7	GFDL	0,166666667
	CMC2	7	5	2	5	5	4	6	4	5	43	17,1	CMC2	0,170634921
	CMC1	4	1	1	3	3	3	2	3	1	21	8,3	CMC1	0,083333333
CFSV2	5	3	4	4	4	6	4	6	3	39	15,5	CFSV2	0,154761905	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Octubre	NMME	3	7	7	3	4	2	7	2	7	42	16,7	NMME	0,166666667
	NCAR_CCSM4	1	2	1	1	7	1	5	1	2	21	8,3	NCAR_CCSM4	0,083333333
	NASA	2	3	3	2	5	3	3	3	4	28	11,1	NASA	0,111111111
	GFDL	5	1	2	5	6	5	1	5	1	31	12,3	GFDL	0,123015873
	CMC2	6	4	5	4	2	7	2	7	3	40	15,9	CMC2	0,158730159
	CMC1	7	6	6	7	3	6	6	6	6	53	21,0	CMC1	0,21031746
CFSV2	4	5	4	6	1	4	4	4	5	37	14,7	CFSV2	0,146825397	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Noviembre	NMME	4	7	7	2	6	2	7	2	7	44	17,5	NMME	0,174603175
	NCAR_CCSM4	5	1	1	1	7	1	1	1	1	19	7,5	NCAR_CCSM4	0,075396825
	NASA	1	4	2	4	4	3	4	4	4	30	11,9	NASA	0,119047619
	GFDL	6	2	4	7	3	5	3	5	3	38	15,1	GFDL	0,150793651
	CMC2	3	6	6	3	1	7	6	7	6	45	17,9	CMC2	0,178571429
	CMC1	2	5	5	5	5	4	2	3	5	36	14,3	CMC1	0,142857143
CFSV2	7	3	3	6	2	6	5	6	2	40	15,9	CFSV2	0,158730159	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Diciembre	NMME	3	4	5	1	4	5	5	6	5	38	15,1	NMME	0,150793651
	NCAR_CCSM4	4	5	2	2	5	1	3	1	4	27	10,7	NCAR_CCSM4	0,107142857
	NASA	2	2	1	3	7	2	2	2	2	23	9,1	NASA	0,091269841
	GFDL	1	3	4	6	1	3	4	3	3	28	11,1	GFDL	0,111111111
	CMC2	7	1	3	4	6	6	1	4	1	33	13,1	CMC2	0,130952381
	CMC1	6	7	7	5	3	7	7	7	7	56	22,2	CMC1	0,222222222
CFSV2	5	6	6	7	2	4	6	5	6	47	18,7	CFSV2	0,186507937	

Tabla 8. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de julio

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Agosto	NMME	7	6	6	7	2	4	6	4	6	48	19,0	NMME	0,19047619
	NCAR_CCSM4	2	4	5	4	4	1	4	1	5	30	11,9	NCAR_CCSM4	0,119047619
	NASA	5	3	2	3	6	6	3	6	4	38	15,1	NASA	0,150793651
	GFDL	1	2	3	2	7	2	2	2	2	23	9,1	GFDL	0,091269841
	CMC2	6	7	7	6	1	7	7	7	7	55	21,8	CMC2	0,218253968
	CMC1	3	5	4	5	3	3	5	3	3	34	13,5	CMC1	0,134920635
	CFSV2	4	1	1	1	5	5	1	5	1	24	9,5	CFSV2	0,095238095
Septiembre	NMME	6	4	3	4	3	3	5	3	5	36	14,3	NMME	0,142857143
	NCAR_CCSM4	7	7	7	7	1	6	7	6	7	55	21,8	NCAR_CCSM4	0,218253968
	NASA	2	1	1	1	7	4	1	4	1	22	8,7	NASA	0,087301587
	GFDL	4	6	6	6	2	7	6	7	6	50	19,8	GFDL	0,198412698
	CMC2	1	5	4	2	6	1	4	1	4	28	11,1	CMC2	0,111111111
	CMC1	3	2	2	3	5	2	2	2	2	23	9,1	CMC1	0,091269841
	CFSV2	5	3	5	5	4	5	3	5	3	38	15,1	CFSV2	0,150793651
Octubre	NMME	5	3	2	2	5	2	3	2	3	27	10,7	NMME	0,107142857
	NCAR_CCSM4	1	1	1	1	7	1	1	1	1	15	6,0	NCAR_CCSM4	0,05952381
	NASA	2	2	3	3	6	5	2	5	2	30	11,9	NASA	0,119047619
	GFDL	6	4	4	5	4	4	4	4	4	39	15,5	GFDL	0,154761905
	CMC2	3	6	7	4	3	7	6	7	6	49	19,4	CMC2	0,194444444
	CMC1	7	5	5	6	2	6	5	6	5	47	18,7	CMC1	0,186507937
	CFSV2	4	7	6	7	1	3	7	3	7	45	17,9	CFSV2	0,178571429
Noviembre	NMME	5	6	4	5	3	1	7	2	7	40	15,9	NMME	0,158730159
	NCAR_CCSM4	3	3	3	2	5	2	4	1	3	26	10,3	NCAR_CCSM4	0,103174603
	NASA	1	1	1	1	7	3	1	3	1	19	7,5	NASA	0,075396825
	GFDL	7	5	6	7	1	4	6	5	5	46	18,3	GFDL	0,182539683
	CMC2	2	7	7	4	4	7	5	6	6	48	19,0	CMC2	0,19047619
	CMC1	4	2	2	3	6	5	2	4	2	30	11,9	CMC1	0,119047619
	CFSV2	6	4	5	6	2	6	3	7	4	43	17,1	CFSV2	0,170634921
Diciembre	NMME	3	6	6	6	2	6	5	7	6	47	18,7	NMME	0,186507937
	NCAR_CCSM4	4	2	3	4	4	4	3	3	2	29	11,5	NCAR_CCSM4	0,115079365
	NASA	2	3	2	2	6	5	2	5	4	31	12,3	NASA	0,123015873
	GFDL	1	1	1	1	7	1	1	1	1	15	6,0	GFDL	0,05952381
	CMC2	7	4	4	3	5	2	4	2	3	34	13,5	CMC2	0,134920635
	CMC1	5	7	7	5	1	7	7	6	7	52	20,6	CMC1	0,206349206
	CFSV2	6	5	5	7	3	3	6	4	5	44	17,5	CFSV2	0,174603175
Enero	NMME	3	6	6	6	3	7	6	7	6	50	19,8	NMME	0,198412698
	NCAR_CCSM4	4	7	7	4	2	3	7	3	7	44	17,5	NCAR_CCSM4	0,174603175
	NASA	5	5	4	5	4	5	4	6	5	43	17,1	NASA	0,170634921
	GFDL	7	2	1	1	7	1	2	2	2	25	9,9	GFDL	0,099206349
	CMC2	1	3	3	2	5	6	3	5	3	31	12,3	CMC2	0,123015873
	CMC1	6	1	2	3	6	2	1	1	1	23	9,1	CMC1	0,091269841
	CFSV2	2	4	5	7	1	4	5	4	4	36	14,3	CFSV2	0,142857143

Tabla 9. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de agosto

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Septiembre	NMME	4	6	4	5	3	5	5	6	6	44	17,5	NMME	0,174603175
	NCAR_CCSM4	2	7	7	4	4	4	7	4	7	46	18,3	NCAR_CCSM4	0,182539683
	NASA	5	4	3	6	2	6	4	5	4	39	15,5	NASA	0,154761905
	GFDL	7	5	6	7	1	7	6	7	5	51	20,2	GFDL	0,202380952
	CMC2	3	1	1	1	7	1	1	2	1	18	7,1	CMC2	0,071428571
	CMC1	1	2	2	2	6	2	2	1	2	20	7,9	CMC1	0,079365079
CFSV2	6	3	5	3	5	3	3	3	3	34	13,5	CFSV2	0,134920635	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Octubre	NMME	3	3	2	2	6	2	3	2	3	26	10,3	NMME	0,103174603
	NCAR_CCSM4	1	1	1	1	7	3	1	3	1	19	7,5	NCAR_CCSM4	0,075396825
	NASA	4	6	5	5	3	5	6	5	6	45	17,9	NASA	0,178571429
	GFDL	7	5	6	7	1	7	5	7	5	50	19,8	GFDL	0,198412698
	CMC2	6	7	7	3	2	6	7	6	7	51	20,2	CMC2	0,202380952
	CMC1	5	2	3	4	5	1	2	1	2	25	9,9	CMC1	0,099206349
CFSV2	2	4	4	6	4	4	4	4	4	36	14,3	CFSV2	0,142857143	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Noviembre	NMME	5	6	6	7	1	5	7	4	6	47	18,7	NMME	0,186507937
	NCAR_CCSM4	4	7	5	3	2	6	6	6	7	46	18,3	NCAR_CCSM4	0,182539683
	NASA	3	2	2	4	4	1	2	3	1	22	8,7	NASA	0,087301587
	GFDL	7	1	1	6	5	4	1	1	3	29	11,5	GFDL	0,115079365
	CMC2	1	5	7	2	6	7	4	7	5	44	17,5	CMC2	0,174603175
	CMC1	2	4	3	1	7	2	3	2	4	28	11,1	CMC1	0,111111111
CFSV2	6	3	4	5	3	3	5	5	2	36	14,3	CFSV2	0,142857143	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Diciembre	NMME	3	6	7	6	1	5	6	6	6	46	18,3	NMME	0,182539683
	NCAR_CCSM4	5	3	3	5	4	3	3	5	3	34	13,5	NCAR_CCSM4	0,134920635
	NASA	1	2	2	3	6	2	2	2	2	22	8,7	NASA	0,087301587
	GFDL	2	1	1	1	7	1	1	1	1	16	6,3	GFDL	0,063492063
	CMC2	7	5	4	2	5	7	5	7	5	47	18,7	CMC2	0,186507937
	CMC1	4	4	5	4	3	6	4	4	4	38	15,1	CMC1	0,150793651
CFSV2	6	7	6	7	2	4	7	3	7	49	19,4	CFSV2	0,194444444	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Enero	NMME	3	2	2	4	5	1	2	1	2	22	8,7	NMME	0,087301587
	NCAR_CCSM4	2	6	6	7	1	6	6	6	6	46	18,3	NCAR_CCSM4	0,182539683
	NASA	5	7	7	3	4	7	7	7	7	54	21,4	NASA	0,214285714
	GFDL	7	4	5	5	2	4	3	4	4	38	15,1	GFDL	0,150793651
	CMC2	1	3	3	2	6	3	4	3	3	28	11,1	CMC2	0,111111111
	CMC1	4	1	1	1	7	2	1	2	1	20	7,9	CMC1	0,079365079
CFSV2	6	5	4	6	3	5	5	5	5	44	17,5	CFSV2	0,174603175	

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Febrero	NMME	2	1	1	1	6	3	1	2	1	18	7,1	NMME	0,071428571
	NCAR_CCSM4	4	6	6	6	2	7	7	7	6	51	20,2	NCAR_CCSM4	0,202380952
	NASA	5	4	3	3	4	4	3	4	4	34	13,5	NASA	0,134920635
	GFDL	3	7	7	7	1	6	6	6	7	50	19,8	GFDL	0,198412698
	CMC2	6	3	4	4	5	5	4	5	3	39	15,5	CMC2	0,154761905
	CMC1	1	2	2	2	7	2	2	3	2	23	9,1	CMC1	0,091269841
CFSV2	7	5	5	5	3	1	5	1	5	37	14,7	CFSV2	0,146825397	

Tabla 10. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de septiembre

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Octubre	NMME	5	5	5	5	3	4	6	4	6	43	17,1	NMME	0,170634921
	NCAR_CCSM4	7	6	6	3	5	2	5	3	5	42	16,7	NCAR_CCSM4	0,166666667
	NASA	1	4	2	6	2	3	4	2	4	28	11,1	NASA	0,111111111
	GFDL	6	1	3	2	6	5	2	5	2	32	12,7	GFDL	0,126984127
	CMC2	4	7	7	7	1	7	7	7	7	54	21,4	CMC2	0,214285714
	CMC1	3	3	4	4	4	1	3	1	3	26	10,3	CMC1	0,103174603
	CFSV2	2	2	1	1	7	6	1	6	1	27	10,7	CFSV2	0,107142857
Noviembre	NMME	3	1	1	2	3	5	1	5	1	22	8,7	NMME	0,087301587
	NCAR_CCSM4	4	5	4	5	5	4	7	4	5	43	17,1	NCAR_CCSM4	0,170634921
	NASA	5	4	5	4	4	3	2	3	4	34	13,5	NASA	0,134920635
	GFDL	7	6	7	7	1	6	6	6	6	52	20,6	GFDL	0,206349206
	CMC2	2	3	2	1	7	2	5	1	3	26	10,3	CMC2	0,103174603
	CMC1	1	2	3	3	6	1	3	2	2	23	9,1	CMC1	0,091269841
	CFSV2	6	7	6	6	2	7	4	7	7	52	20,6	CFSV2	0,206349206
Diciembre	NMME	5	6	6	3	2	3	4	4	6	39	15,5	NMME	0,154761905
	NCAR_CCSM4	3	2	2	5	7	1	2	1	2	25	9,9	NCAR_CCSM4	0,099206349
	NASA	1	3	4	6	3	2	1	2	1	23	9,1	NASA	0,091269841
	GFDL	2	1	1	4	4	6	3	3	3	27	10,7	GFDL	0,107142857
	CMC2	7	5	5	2	6	4	6	5	5	45	17,9	CMC2	0,178571429
	CMC1	6	7	3	1	5	5	7	6	7	47	18,7	CMC1	0,186507937
	CFSV2	4	4	7	7	1	7	5	7	4	46	18,3	CFSV2	0,182539683
Enero	NMME	5	6	6	6	2	6	7	6	6	50	19,8	NMME	0,198412698
	NCAR_CCSM4	4	5	5	5	3	3	5	3	5	38	15,1	NCAR_CCSM4	0,150793651
	NASA	2	1	1	2	7	1	1	1	1	17	6,7	NASA	0,067460317
	GFDL	7	2	2	4	5	5	2	5	2	34	13,5	GFDL	0,134920635
	CMC2	1	3	4	1	6	4	3	4	3	29	11,5	CMC2	0,115079365
	CMC1	3	4	3	3	4	2	4	2	4	29	11,5	CMC1	0,115079365
	CFSV2	6	7	7	7	1	7	6	7	7	55	21,8	CFSV2	0,218253968
Febrero	NMME	5	2	3	5	3	2	1	2	2	25	9,9	NMME	0,099206349
	NCAR_CCSM4	3	3	6	7	2	5	3	4	3	36	14,3	NCAR_CCSM4	0,142857143
	NASA	1	7	7	6	1	7	7	7	7	50	19,8	NASA	0,198412698
	GFDL	2	6	4	3	5	6	5	6	6	43	17,1	GFDL	0,170634921
	CMC2	6	4	2	1	7	1	4	1	5	31	12,3	CMC2	0,123015873
	CMC1	7	5	5	2	4	3	6	3	4	39	15,5	CMC1	0,154761905
	CFSV2	4	1	1	4	6	4	2	5	1	28	11,1	CFSV2	0,111111111
Marzo	NMME	5	1	1	4	7	1	1	1	1	22	8,7	NMME	0,087301587
	NCAR_CCSM4	6	7	6	6	1	3	7	2	7	45	17,9	NCAR_CCSM4	0,178571429
	NASA	1	6	7	7	2	5	6	5	6	45	17,9	NASA	0,178571429
	GFDL	7	5	4	5	3	7	5	7	5	48	19,0	GFDL	0,19047619
	CMC2	2	2	3	1	6	2	2	3	2	23	9,1	CMC2	0,091269841
	CMC1	3	3	5	2	5	4	4	4	3	33	13,1	CMC1	0,130952381
	CFSV2	4	4	2	3	4	6	3	6	4	36	14,3	CFSV2	0,142857143

Tabla 11. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de octubre

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Noviembre	NMME	5	5	2	4	5	2	5	4	4	36	14,3	NMME	0,142857143
	NCAR_CCSM4	3	2	5	5	3	6	3	6	3	36	14,3	NCAR_CCSM4	0,142857143
	NASA	1	1	1	1	7	4	1	5	2	23	9,1	NASA	0,091269841
	GFDL	6	3	4	3	2	3	2	2	1	26	10,3	GFDL	0,103174603
	CMC2	4	7	7	6	4	5	6	3	7	49	19,4	CMC2	0,194444444
	CMC1	2	4	3	2	6	1	4	1	5	28	11,1	CMC1	0,111111111
	CFSV2	7	6	6	7	1	7	7	7	6	54	21,4	CFSV2	0,214285714

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Diciembre	NMME	4	4	4	5	2	4	4	4	4	35	13,9	NMME	0,138888889
	NCAR_CCSM4	5	5	5	3	4	6	6	7	6	47	18,7	NCAR_CCSM4	0,186507937
	NASA	2	1	1	1	7	1	1	2	1	17	6,7	NASA	0,067460317
	GFDL	1	6	6	6	3	3	3	3	5	36	14,3	GFDL	0,142857143
	CMC2	6	3	3	2	5	7	5	6	3	40	15,9	CMC2	0,158730159
	CMC1	7	7	7	7	1	5	7	5	7	53	21,0	CMC1	0,21031746
	CFSV2	3	2	2	4	6	2	2	1	2	24	9,5	CFSV2	0,095238095

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Enero	NMME	6	5	5	6	2	3	6	4	5	42	16,7	NMME	0,166666667
	NCAR_CCSM4	1	2	3	3	4	4	1	3	2	23	9,1	NCAR_CCSM4	0,091269841
	NASA	2	6	6	5	3	6	5	6	6	45	17,9	NASA	0,178571429
	GFDL	5	3	1	2	6	5	4	5	4	35	13,9	GFDL	0,138888889
	CMC2	3	4	4	4	5	2	2	1	3	28	11,1	CMC2	0,111111111
	CMC1	4	1	2	1	7	1	3	2	1	22	8,7	CMC1	0,087301587
	CFSV2	7	7	7	7	1	7	7	7	7	57	22,6	CFSV2	0,226190476

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Febrero	NMME	5	6	7	6	2	4	7	5	6	48	19,0	NMME	0,19047619
	NCAR_CCSM4	1	2	1	5	6	3	2	3	2	25	9,9	NCAR_CCSM4	0,099206349
	NASA	6	3	3	2	4	7	3	7	4	39	15,5	NASA	0,154761905
	GFDL	3	7	5	4	3	6	5	6	7	46	18,3	GFDL	0,182539683
	CMC2	4	4	4	7	5	1	6	2	3	36	14,3	CMC2	0,142857143
	CMC1	2	1	2	3	7	2	1	1	1	20	7,9	CMC1	0,079365079
	CFSV2	7	5	6	1	1	5	4	4	5	38	15,1	CFSV2	0,150793651

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Marzo	NMME	5	4	4	5	3	4	4	4	4	37	14,7	NMME	0,146825397
	NCAR_CCSM4	4	2	3	4	5	5	3	5	2	33	13,1	NCAR_CCSM4	0,130952381
	NASA	1	1	1	1	7	2	1	2	1	17	6,7	NASA	0,067460317
	GFDL	7	7	6	7	1	7	7	7	7	56	22,2	GFDL	0,222222222
	CMC2	3	5	5	6	4	1	5	3	5	37	14,7	CMC2	0,146825397
	CMC1	6	6	7	3	2	6	6	6	6	48	19,0	CMC1	0,19047619
	CFSV2	2	3	2	2	6	3	2	1	3	24	9,5	CFSV2	0,095238095

Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Abril	NMME	3	6	6	6	2	5	4	4	6	42	16,7	NMME	0,166666667
	NCAR_CCSM4	5	3	3	2	5	1	2	1	3	25	9,9	NCAR_CCSM4	0,099206349
	NASA	7	7	7	7	1	7	7	7	7	57	22,6	NASA	0,226190476
	GFDL	4	5	4	4	4	4	5	5	5	40	15,9	GFDL	0,158730159
	CMC2	2	4	5	5	3	6	6	6	4	41	16,3	CMC2	0,162698413
	CMC1	1	1	1	3	6	3	1	2	1	19	7,5	CMC1	0,075396825
	CFSV2	6	2	2	1	7	2	3	3	2	28	11,1	CFSV2	0,111111111

Tabla 12. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de noviembre



Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Diciembre	NMME	3	7	7	6	1	7	7	7	7	52	20,6	NMME	0,206349206
	NCAR_CCSM4	4	4	6	5	3	6	3	6	4	41	16,3	NCAR_CCSM4	0,162698413
	NASA	1	5	4	3	4	5	6	4	5	37	14,7	NASA	0,146825397
	GFDL	5	3	5	7	2	3	2	1	3	31	12,3	GFDL	0,123015873
	CMC2	7	2	3	4	5	1	5	3	2	32	12,7	CMC2	0,126984127
	CMC1	6	1	2	2	6	2	1	2	1	23	9,1	CMC1	0,091269841
	CFSV2	2	6	1	1	7	4	4	5	6	36	14,3	CFSV2	0,142857143
Enero	NMME	7	6	5	6	3	6	6	6	6	51	20,2	NMME	0,202380952
	NCAR_CCSM4	4	7	7	5	2	7	7	7	7	53	21,0	NCAR_CCSM4	0,21031746
	NASA	5	2	1	2	6	2	2	2	2	24	9,5	NASA	0,095238095
	GFDL	6	5	3	3	5	5	5	5	5	42	16,7	GFDL	0,166666667
	CMC2	1	1	2	1	7	1	1	1	1	16	6,3	CMC2	0,063492063
	CMC1	3	4	6	7	1	4	3	4	4	36	14,3	CMC1	0,142857143
	CFSV2	2	3	4	4	4	3	4	3	3	30	11,9	CFSV2	0,119047619
Febrero	NMME	3	2	1	1	7	4	2	3	2	25	9,9	NMME	0,099206349
	NCAR_CCSM4	4	5	5	6	3	5	4	4	5	41	16,3	NCAR_CCSM4	0,162698413
	NASA	2	3	3	4	5	2	3	2	3	27	10,7	NASA	0,107142857
	GFDL	1	7	6	5	1	7	7	7	7	48	19,0	GFDL	0,19047619
	CMC2	6	1	2	2	6	1	1	1	1	21	8,3	CMC2	0,083333333
	CMC1	5	4	4	3	4	6	6	6	4	42	16,7	CMC1	0,166666667
	CFSV2	7	6	7	7	2	3	5	5	6	48	19,0	CFSV2	0,19047619
Marzo	NMME	3	1	1	2	7	2	2	2	1	21	8,3	NMME	0,083333333
	NCAR_CCSM4	4	2	3	1	6	3	1	3	2	25	9,9	NCAR_CCSM4	0,099206349
	NASA	1	4	5	5	2	5	5	5	4	36	14,3	NASA	0,142857143
	GFDL	7	7	7	6	1	7	7	7	7	56	22,2	GFDL	0,222222222
	CMC2	2	3	2	3	5	1	3	1	3	23	9,1	CMC2	0,091269841
	CMC1	6	5	6	4	4	6	4	6	5	46	18,3	CMC1	0,182539683
	CFSV2	5	6	4	7	3	4	6	4	6	45	17,9	CFSV2	0,178571429
Abril	NMME	2	2	5	6	3	4	3	4	3	32	12,7	NMME	0,126984127
	NCAR_CCSM4	3	3	2	1	7	3	4	3	2	28	11,1	NCAR_CCSM4	0,111111111
	NASA	7	7	7	7	1	2	6	2	7	46	18,3	NASA	0,182539683
	GFDL	4	4	4	4	4	7	2	7	4	40	15,9	GFDL	0,158730159
	CMC2	1	1	1	2	6	5	5	5	1	27	10,7	CMC2	0,107142857
	CMC1	6	5	3	3	5	1	1	1	5	30	11,9	CMC1	0,119047619
	CFSV2	5	6	6	5	2	6	7	6	6	49	19,4	CFSV2	0,194444444
Mayo	NMME	1	1	2	3	6	2	1	2	1	19	7,5	NMME	0,075396825
	NCAR_CCSM4	3	7	7	6	4	4	7	3	7	48	19,0	NCAR_CCSM4	0,19047619
	NASA	5	6	5	7	1	7	6	7	6	50	19,8	NASA	0,198412698
	GFDL	7	4	3	1	5	1	4	4	4	33	13,1	GFDL	0,130952381
	CMC2	2	2	1	2	7	3	2	1	2	22	8,7	CMC2	0,087301587
	CMC1	4	3	6	4	2	6	3	6	3	37	14,7	CMC1	0,146825397
	CFSV2	6	5	4	5	3	5	5	5	5	43	17,1	CFSV2	0,170634921

Tabla 13. Promedio ponderado nacional del ensamble de modelos NMME para la predicción mensual de precipitación a un horizonte de pronóstico de seis meses con condiciones iniciales de diciembre



Mes a pronosticar	Modelo	goodness index	2AFC	Gerrity Score	Hit	LEPS	MAE	PEARSON	RMSE	SPEARMAN	Total	Porcentaje	Modelo	Coefficientes
Enero	NMME	6	4	4	3	5	4	4	5	4	39	15,5	NMME	0,154761905
	NCAR_CCSM4	2	7	7	5	1	7	7	7	7	50	19,8	NCAR_CCSM4	0,198412698
	NASA	1	1	1	1	7	1	1	1	1	15	6,0	NASA	0,05952381
	GFDL	7	6	3	7	2	6	6	6	6	49	19,4	GFDL	0,194444444
	CMC2	5	3	5	6	4	3	3	4	3	36	14,3	CMC2	0,142857143
	CMC1	4	2	2	2	6	2	2	2	2	24	9,5	CMC1	0,095238095
	CFSV2	3	5	6	4	3	5	5	3	5	39	15,5	CFSV2	0,154761905
Febrero	NMME	2	2	1	2	7	2	1	2	2	21	8,3	NMME	0,083333333
	NCAR_CCSM4	5	6	7	7	1	6	7	6	6	51	20,2	NCAR_CCSM4	0,202380952
	NASA	7	7	6	5	3	3	6	3	7	47	18,7	NASA	0,186507937
	GFDL	1	1	3	4	5	5	2	5	1	27	10,7	GFDL	0,107142857
	CMC2	6	3	2	1	6	1	3	1	3	26	10,3	CMC2	0,103174603
	CMC1	4	4	4	3	4	4	5	4	4	36	14,3	CMC1	0,142857143
	CFSV2	3	5	5	6	2	7	4	7	5	44	17,5	CFSV2	0,174603175
Marzo	NMME	6	5	6	4	2	4	5	4	5	41	16,3	NMME	0,162698413
	NCAR_CCSM4	7	6	4	2	4	5	6	5	7	46	18,3	NCAR_CCSM4	0,182539683
	NASA	1	3	2	5	6	1	3	1	4	26	10,3	NASA	0,103174603
	GFDL	5	4	3	6	3	6	2	6	3	38	15,1	GFDL	0,150793651
	CMC2	3	2	5	7	5	3	4	3	2	34	13,5	CMC2	0,134920635
	CMC1	4	7	7	3	1	7	7	7	6	49	19,4	CMC1	0,194444444
	CFSV2	2	1	1	1	7	2	1	2	1	18	7,1	CFSV2	0,071428571
Abril	NMME	6	6	6	7	1	5	6	5	6	48	19,0	NMME	0,19047619
	NCAR_CCSM4	5	3	2	2	6	2	3	1	3	27	10,7	NCAR_CCSM4	0,107142857
	NASA	1	5	5	4	5	3	4	3	5	35	13,9	NASA	0,138888889
	GFDL	4	7	7	5	2	6	7	6	7	51	20,2	GFDL	0,202380952
	CMC2	3	4	4	6	4	4	5	4	4	38	15,1	CMC2	0,150793651
	CMC1	7	2	3	3	3	7	2	7	2	36	14,3	CMC1	0,142857143
	CFSV2	2	1	1	1	7	1	1	2	1	17	6,7	CFSV2	0,067460317
Mayo	NMME	4	3	3	5	5	2	4	1	3	30	11,9	NMME	0,119047619
	NCAR_CCSM4	3	4	4	3	4	6	3	6	4	37	14,7	NCAR_CCSM4	0,146825397
	NASA	1	1	1	2	7	4	1	3	1	21	8,3	NASA	0,083333333
	GFDL	2	2	2	1	6	1	2	4	2	22	8,7	GFDL	0,087301587
	CMC2	7	5	5	4	2	3	6	2	6	40	15,9	CMC2	0,158730159
	CMC1	6	6	6	6	3	5	5	5	5	47	18,7	CMC1	0,186507937
	CFSV2	5	7	7	7	1	7	7	7	7	55	21,8	CFSV2	0,218253968
Junio	NMME	5	5	3	6	4	4	4	4	5	40	15,9	NMME	0,158730159
	NCAR_CCSM4	4	2	4	5	6	1	7	1	4	34	13,5	NCAR_CCSM4	0,134920635
	NASA	2	7	7	4	2	7	6	7	7	49	19,4	NASA	0,194444444
	GFDL	1	1	1	1	7	3	1	3	1	19	7,5	GFDL	0,075396825
	CMC2	6	3	2	2	5	2	3	2	3	28	11,1	CMC2	0,111111111
	CMC1	3	4	5	3	1	6	2	6	2	32	12,7	CMC1	0,126984127
	CFSV2	7	6	6	7	3	5	5	5	6	50	19,8	CFSV2	0,198412698

Figura 1. Factor de cambio para los siguientes seis meses con condiciones iniciales de enero


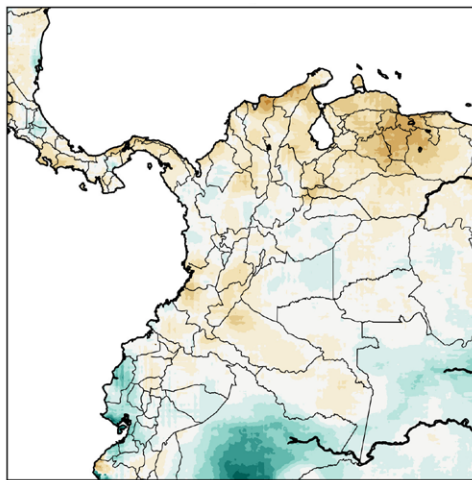
Factor de cambio - Ensamble
Cl: 01 Mes a predecir: 02





Factor de cambio - Ensamble
Cl: 01 Mes a predecir: 03





Factor de cambio - Ensamble
Cl: 01 Mes a predecir: 04



Factor de cambio - Ensamble
Cl: 01 Mes a predecir: 05



Factor de cambio - Ensamble
Cl: 01 Mes a predecir: 06



Factor de cambio - Ensamble
Cl: 01 Mes a predecir: 07


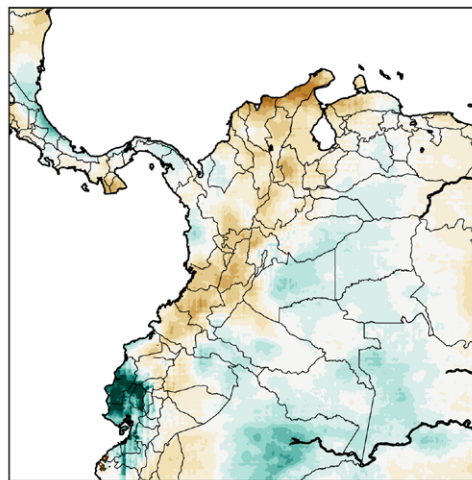


Figura 2. Factor de cambio para los siguientes seis meses con condiciones iniciales de febrero

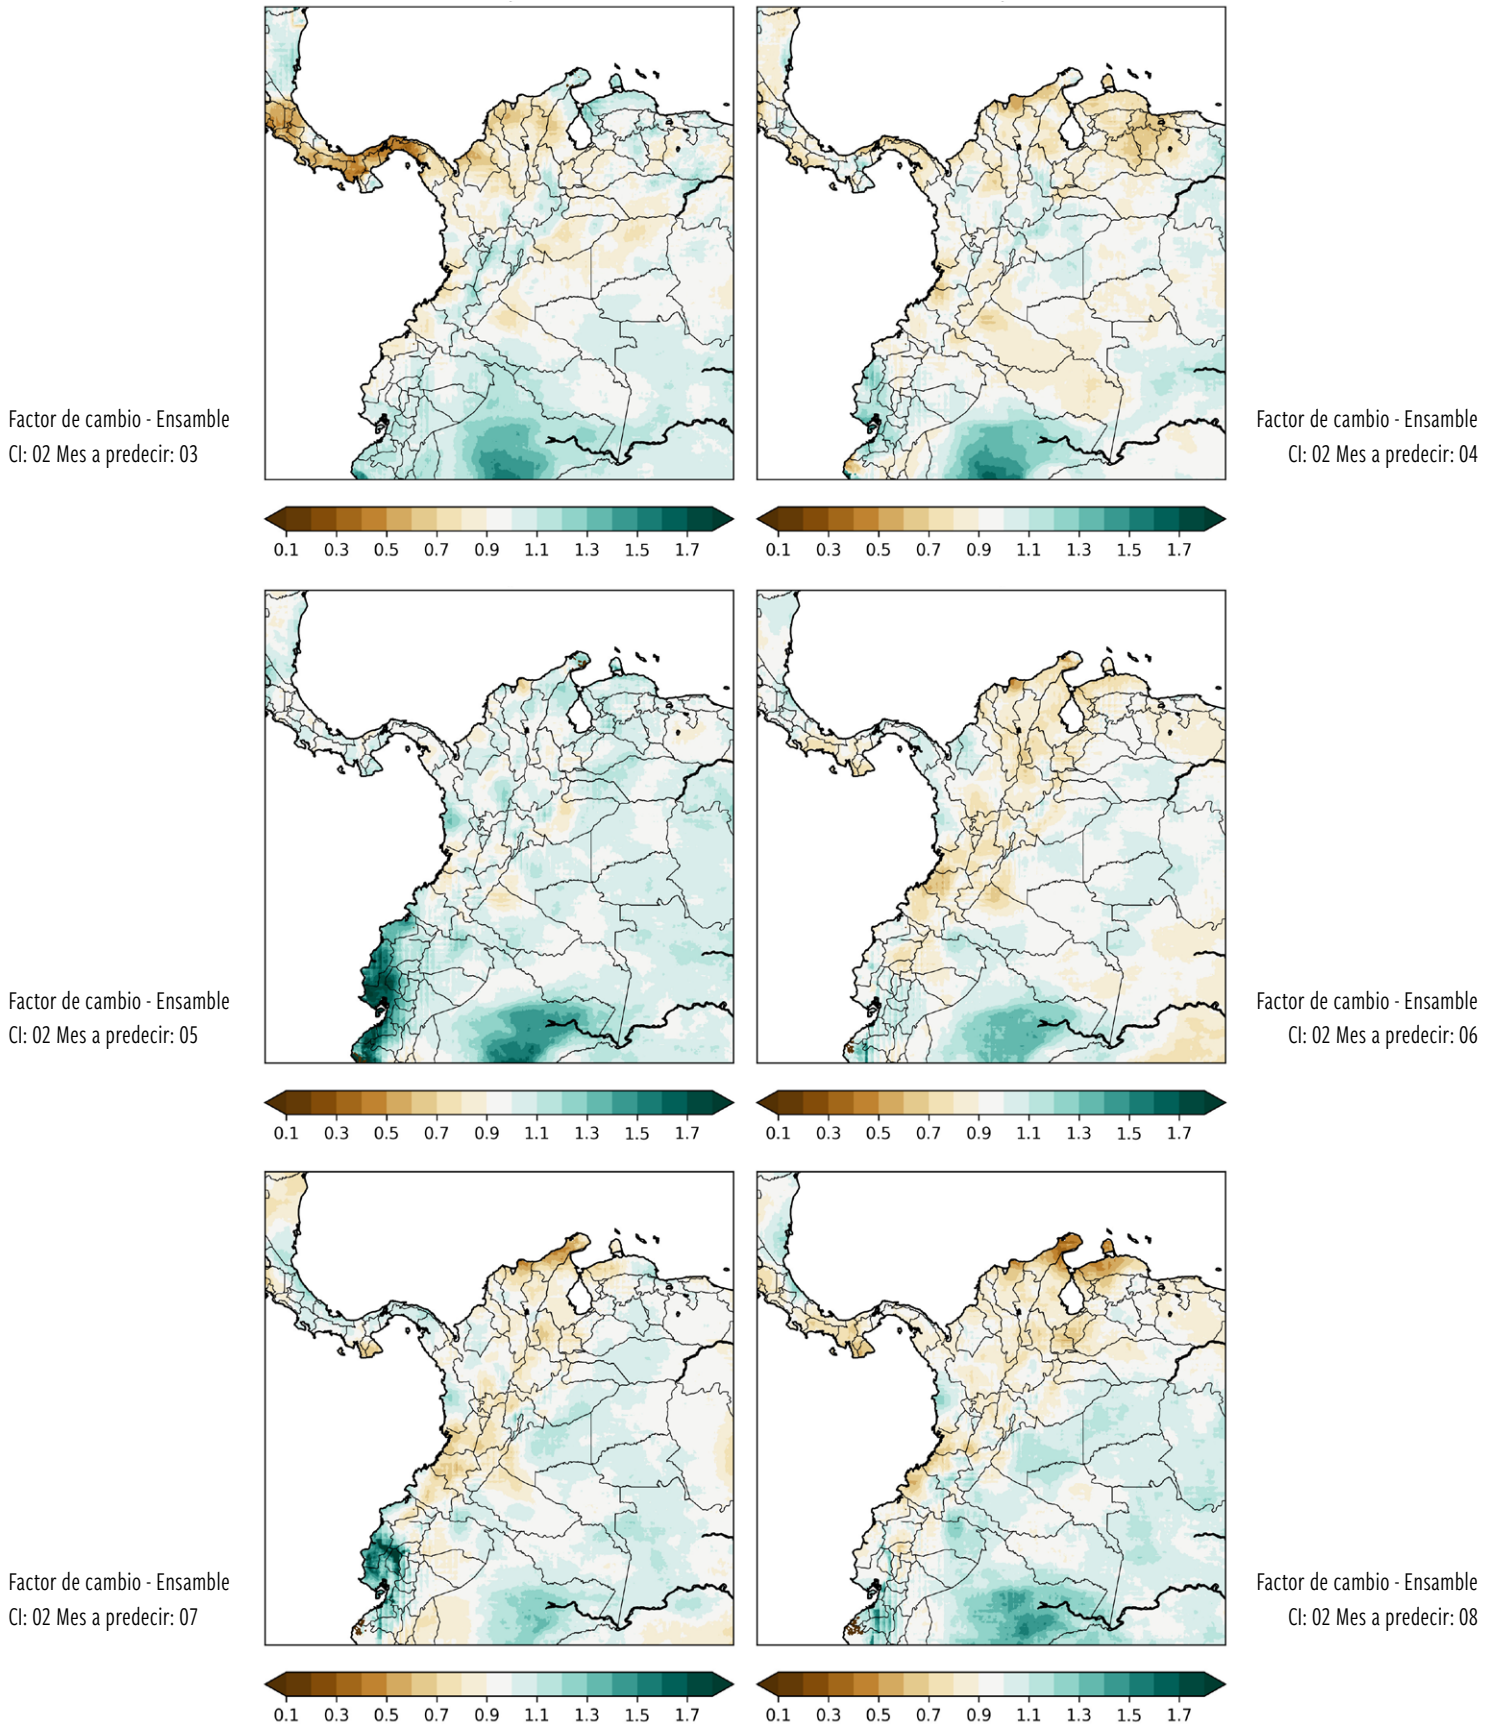





Figura 3. Factor de cambio para los siguientes seis meses con condiciones iniciales de marzo



Factor de cambio - Ensamble
CI: 03 Mes a predecir: 04





Factor de cambio - Ensamble
CI: 03 Mes a predecir: 05




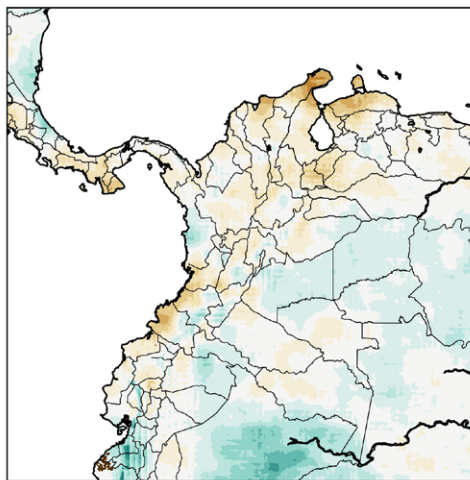
Factor de cambio - Ensamble
CI: 03 Mes a predecir: 06



Factor de cambio - Ensamble
CI: 03 Mes a predecir: 07



Factor de cambio - Ensamble
CI: 03 Mes a predecir: 08



Factor de cambio - Ensamble
CI: 03 Mes a predecir: 09









Figura 4. Factor de cambio para los siguientes seis meses con condiciones iniciales de abril



Factor de cambio - Ensamble
CI: 04 Mes a predecir: 05





Factor de cambio - Ensamble
CI: 04 Mes a predecir: 06





Factor de cambio - Ensamble
CI: 04 Mes a predecir: 07



Factor de cambio - Ensamble
CI: 04 Mes a predecir: 08



Factor de cambio - Ensamble
CI: 04 Mes a predecir: 09



Factor de cambio - Ensamble
CI: 04 Mes a predecir: 10









Figura 5. Factor de cambio para los siguientes seis meses con condiciones iniciales de mayo



Factor de cambio - Ensamble
Ci: 05 Mes a predecir: 06





Factor de cambio - Ensamble
Ci: 05 Mes a predecir: 07





Factor de cambio - Ensamble
Ci: 05 Mes a predecir: 08



Factor de cambio - Ensamble
Ci: 05 Mes a predecir: 09



Factor de cambio - Ensamble
Ci: 05 Mes a predecir: 10



Factor de cambio - Ensamble
Ci: 05 Mes a predecir: 11









Figura 6. Factor de cambio para los siguientes seis meses con condiciones iniciales de junio



Factor de cambio - Ensamble
CI: 06 Mes a predecir: 07





Factor de cambio - Ensamble
CI: 06 Mes a predecir: 08





Factor de cambio - Ensamble
CI: 06 Mes a predecir: 09



Factor de cambio - Ensamble
CI: 06 Mes a predecir: 10



Factor de cambio - Ensamble
CI: 06 Mes a predecir: 11



Factor de cambio - Ensamble
CI: 06 Mes a predecir: 12









Figura 7. Factor de cambio para los siguientes seis meses con condiciones iniciales de julio



Factor de cambio - Ensamble
Cl: 07 Mes a predecir: 08





Factor de cambio - Ensamble
Cl: 07 Mes a predecir: 09




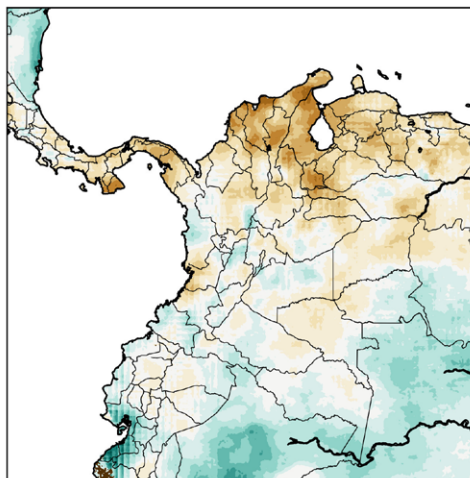
Factor de cambio - Ensamble
Cl: 07 Mes a predecir: 10



Factor de cambio - Ensamble
Cl: 07 Mes a predecir: 11



Factor de cambio - Ensamble
Cl: 07 Mes a predecir: 12



Factor de cambio - Ensamble
Cl: 07 Mes a predecir: 13









Figura 8. Factor de cambio para los siguientes seis meses con condiciones iniciales de agosto



Factor de cambio - Ensamble
Cl: 08 Mes a predecir: 09




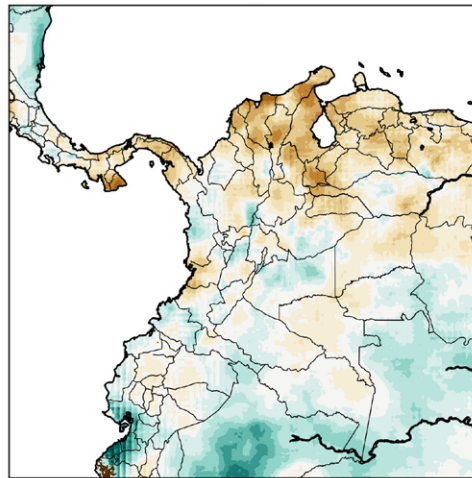
Factor de cambio - Ensamble
Cl: 08 Mes a predecir: 10





Factor de cambio - Ensamble
Cl: 08 Mes a predecir: 11



Factor de cambio - Ensamble
Cl: 08 Mes a predecir: 12



Factor de cambio - Ensamble
Cl: 08 Mes a predecir: 01



Factor de cambio - Ensamble
Cl: 08 Mes a predecir: 02





Figura 9. Factor de cambio para los siguientes seis meses con condiciones iniciales de septiembre

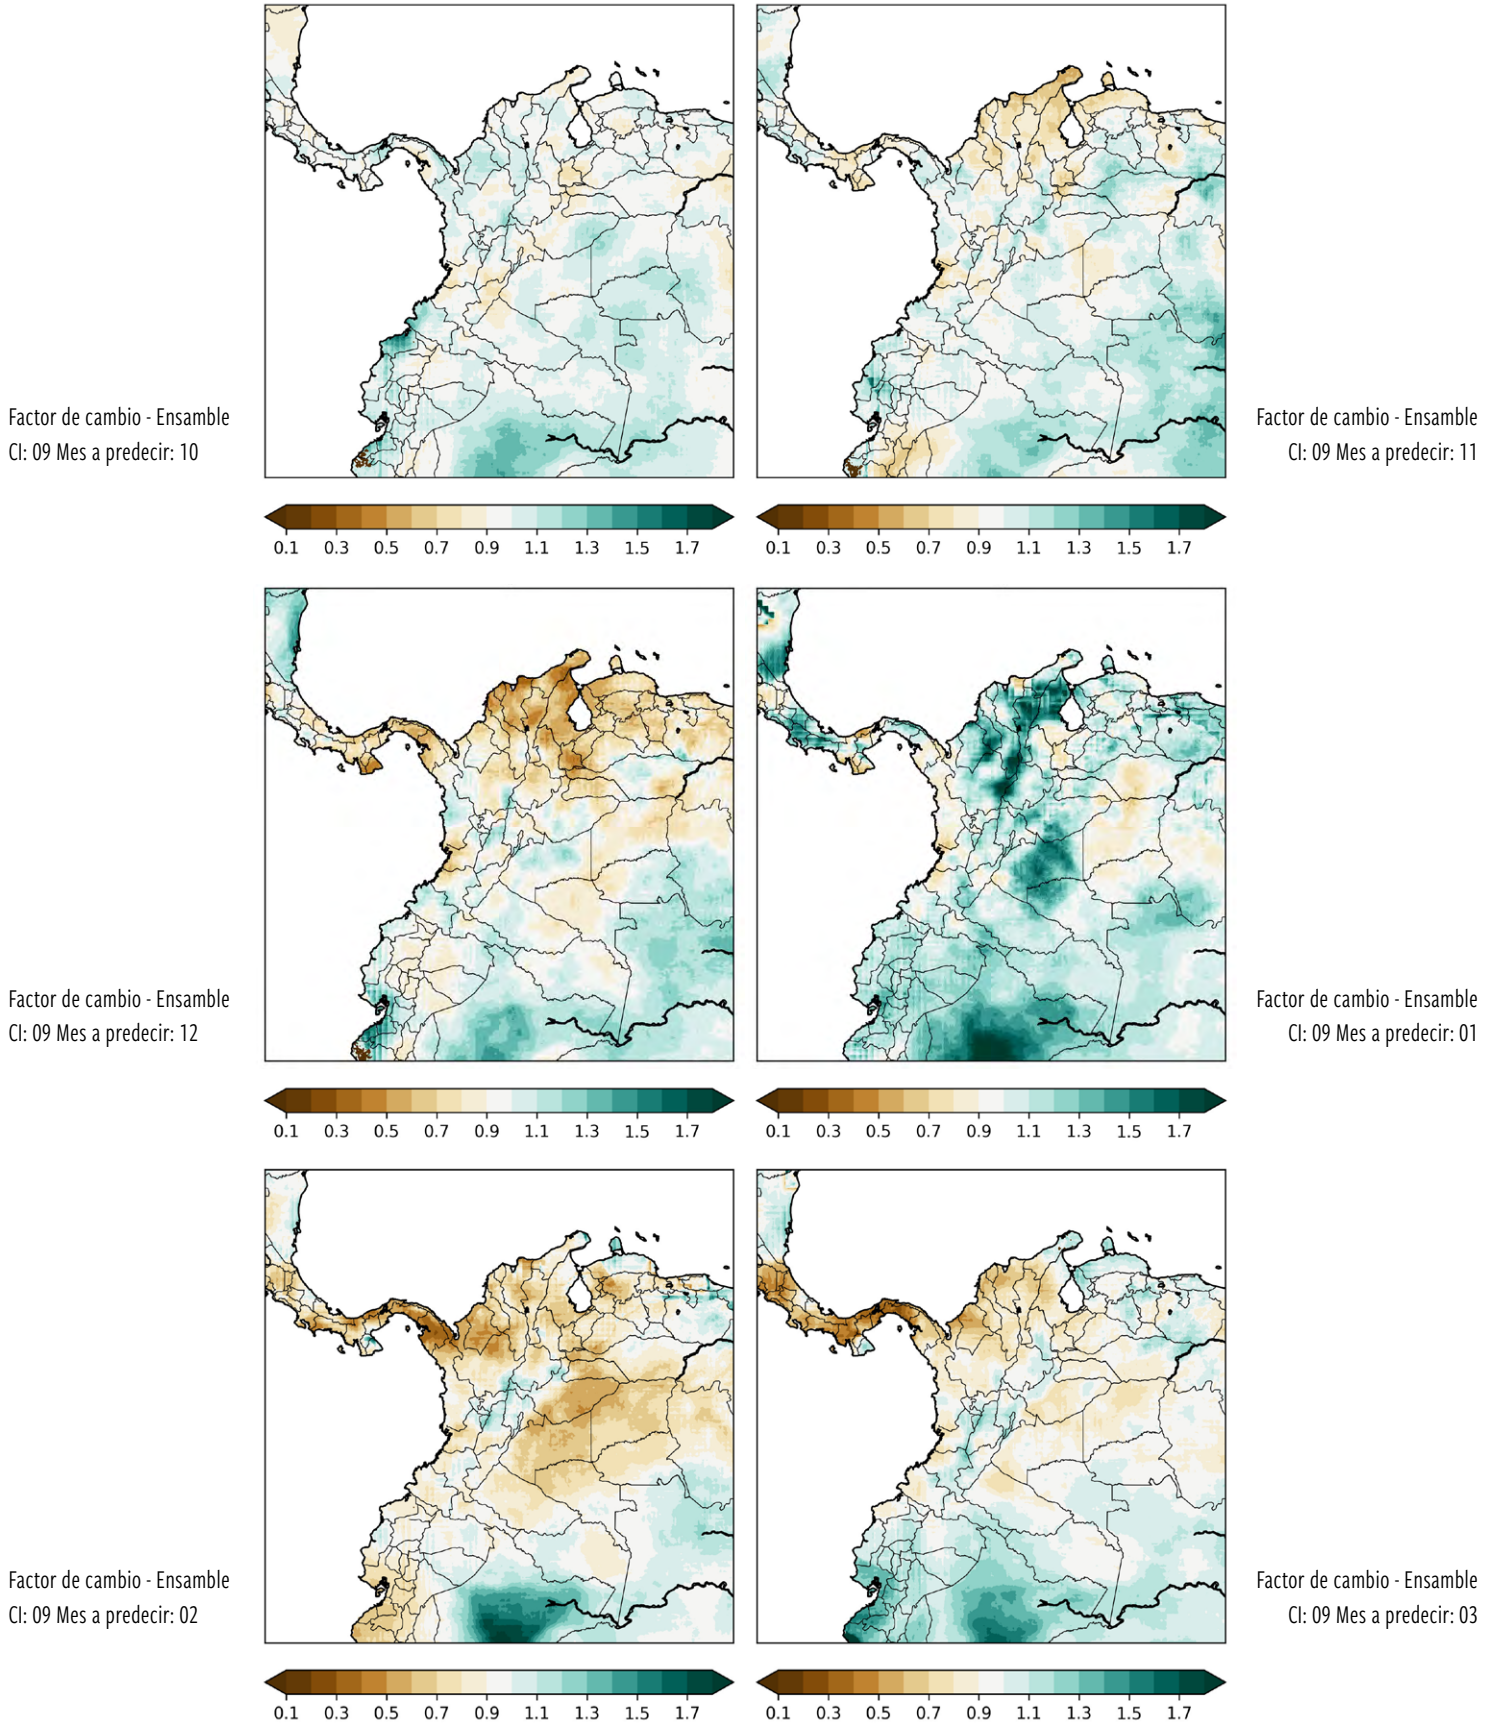






Figura 10. Factor de cambio para los siguientes seis meses con condiciones iniciales de octubre


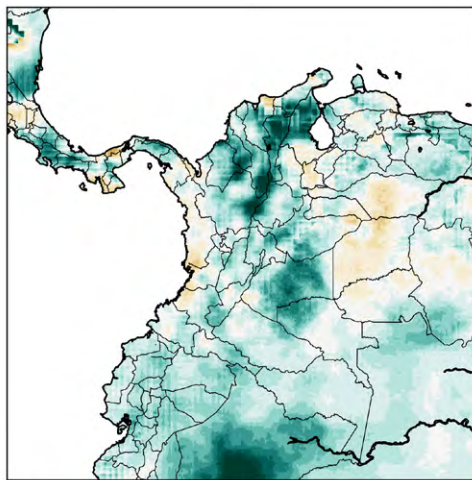
Factor de cambio - Ensamble
Ci: 10 Mes a predecir: 11





Factor de cambio - Ensamble
Ci: 10 Mes a predecir: 12





Factor de cambio - Ensamble
Ci: 10 Mes a predecir: 01



Factor de cambio - Ensamble
Ci: 10 Mes a predecir: 02



Factor de cambio - Ensamble
Ci: 10 Mes a predecir: 03



Factor de cambio - Ensamble
Ci: 10 Mes a predecir: 04


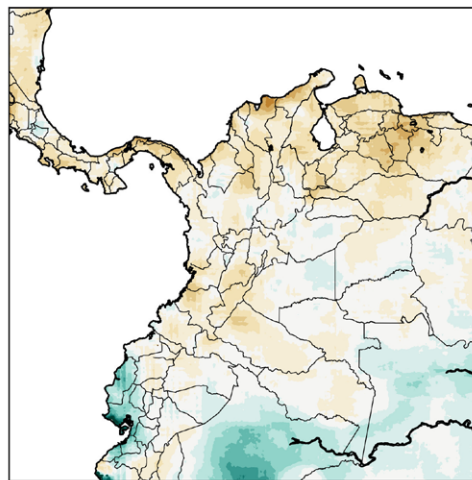


Figura 11. Factor de cambio para los siguientes seis meses con condiciones iniciales de noviembre

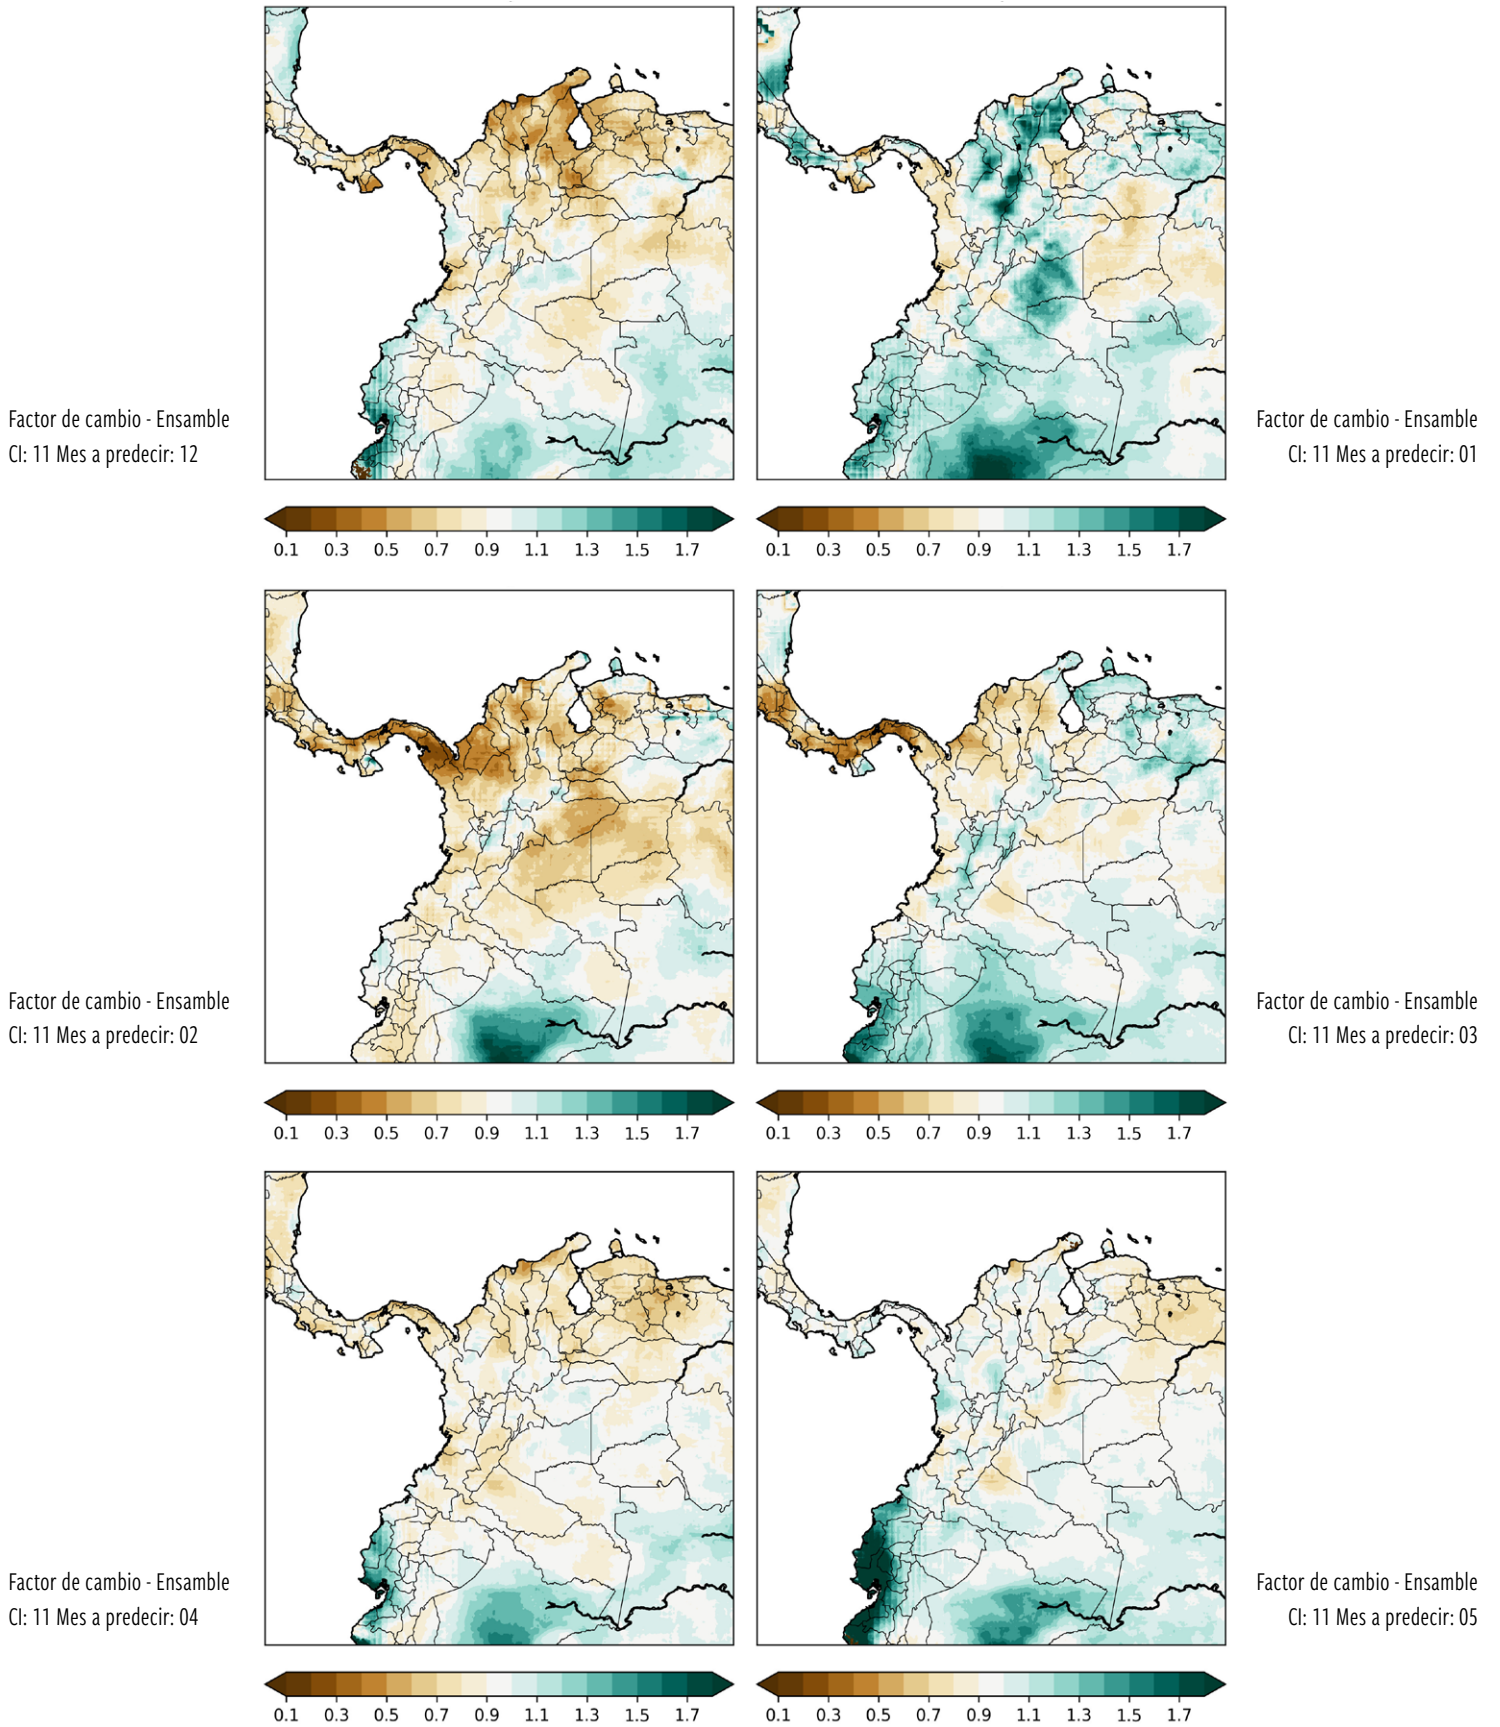
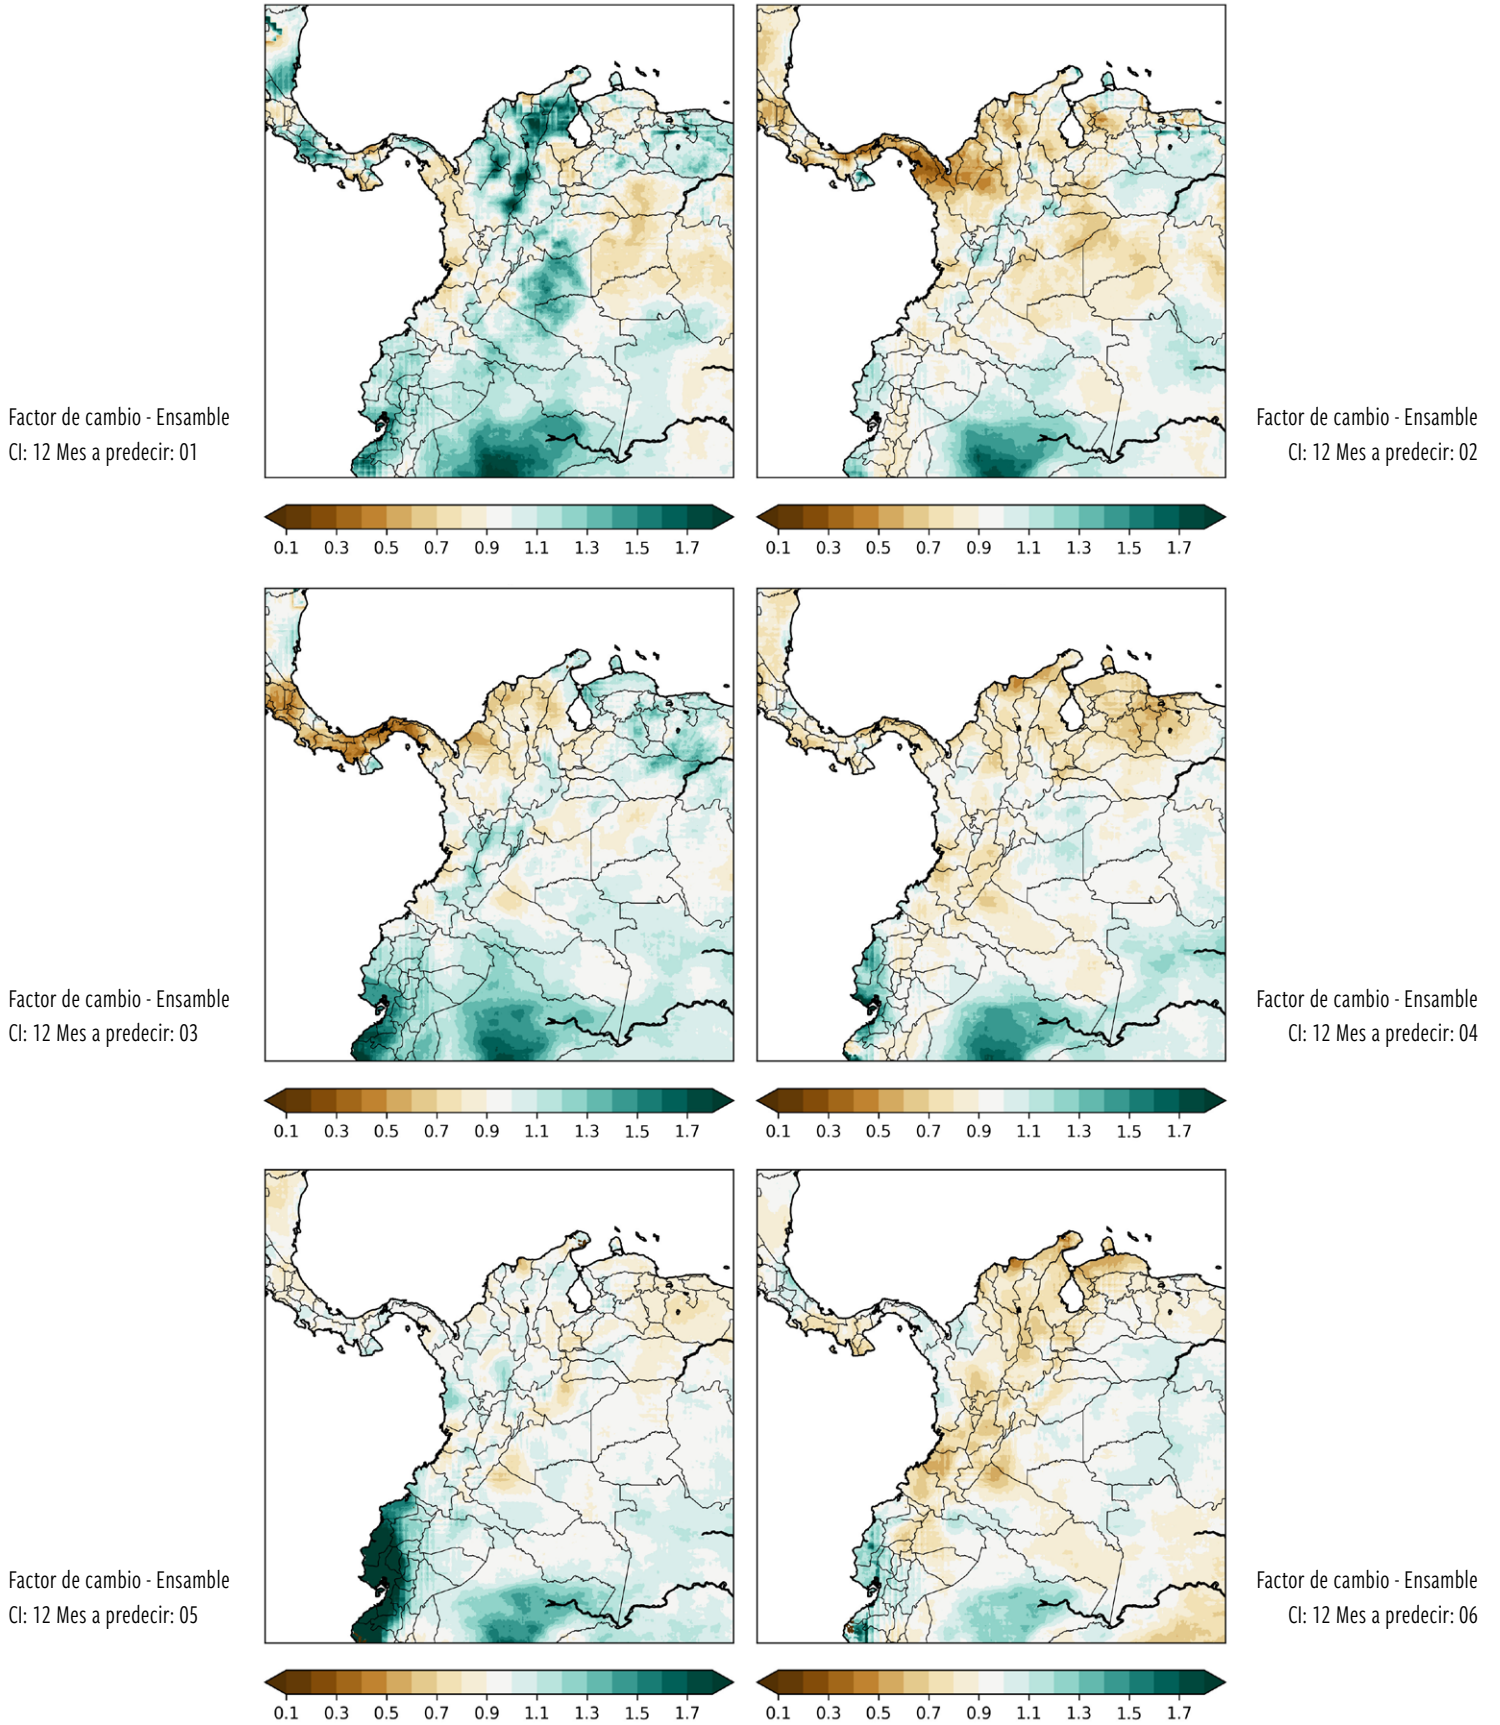


Figura 12. Factor de cambio para los siguientes seis meses con condiciones iniciales de diciembre





5



Conclusiones y recomendaciones

Ningún modelo mostró una ventaja significativa en cuanto a habilidad predictiva respecto a los demás, incluido el ensamble que promedia todos los modelos utilizados por el CPC de la NOAA.

La contribución de cada modelo de la NOAA fue fundamental para la construcción de un ensamble ponderado, el cual demostró ser útil para las predicciones operativas.

Inicialmente, el modelo CFSv2 demostró ser el más efectivo para predecir la precipitación en Colombia y

fue seleccionado para utilizarse en 16 ocasiones dentro del esquema de predicción. Le siguen los modelos GFDL y GEM5.2-NEMO, con 12 aplicaciones cada uno, así como NCAR-CCSM3 y CanEMS5, que se emplearán en 10 oportunidades. Por su parte, el modelo NASA se utilizará en 9 ocasiones, mientras que el modelo NMME (ENSAMBLE MEAN) solo se aplicará en 5 oportunidades, como se muestra en la Tabla 14.

Tabla 14. Mejores modelos de predicción de precipitación mensual para cada una de las condiciones iniciales

CI	MES A PREDECIR																	
	AÑO ACTUAL											AÑO SIGUIENTE						
	FEB	MAR	ABR	MAY	JUN	JUL	AGO	SEP	OCT	NOV	DIC	ENE	FEB	MAR	ABR	MAY	JUN	
ENE	"NCAR-CCSM4 NMME"	NCAR-CCSM4	CFSv2	CFSv2	CanESM5	"NASA GEM5.2- NEMO"												
FEB		CFSv2	GFDL	GEM5.2- NEMO	CanESM5	GFDL	GFDL											
MAR			CFSv2	GEM5.2- NEMO	NASA	GFDL	GFDL	GFDL										
ABR				CanESM5	GFDL	NCAR- CCSM4	NCAR- CCSM4	GEM5.2- NEMO	CanESM5									
MAY					NASA	CFSv2	CFSv2	NCAR- CCSM4	GEM5.2- NEMO	CFSv2								
JUN						GEM5.2- NEMO	NASA	NASA	CanESM5	GEM5.2- NEMO	CanESM5							
JUL							GEM5.2- NEMO	NCAR- CCSM4	GEM5.2- NEMO	GEM5.2- NEMO	CanESM5	NMME						
AGO								GFDL	GEM5.2- NEMO	NMME	CFSv2	NASA	NCAR- CCSM4					
SEP									GEM5.2- NEMO	CFSv2	CanESM5	CFSv2	NASA	GFDL				
OCT										CFSv2	CanESM5	CFSv2	NMME	GFDL	NASA			
NOV											NMME	NCAR- CCSM4	CFSv2	GFDL	CFSv2	NASA		
DIC												NCAR- CCSM4	NCAR- CCSM4	CanESM5	GFDL	CFSv2	CFSv2	

El análisis del factor de cambio permitió determinar un valor de corrección específico para cada punto de la retícula (resolución CHIRPS), lo cual contribuye a generar predicciones operativas más precisas. Además,

este análisis permitió identificar que los errores varían según las condiciones iniciales durante los seis meses de predicción.

Recomendaciones

Es fundamental mejorar este tipo de estudios diferenciando los períodos correspondientes a las tres fases del fenómeno ENOS (El Niño-Oscilación del Sur), lo cual permitiría realizar un análisis más detallado y preciso de los patrones climáticos asociados y la efectividad de las predicciones.

Se recomienda incorporar metodologías de inteligencia artificial en los modelos predictivos, con el objetivo de optimizar tanto la precisión como la capacidad de las predicciones mediante técnicas de aprendizaje automático y el análisis de grandes volúmenes de datos.

Es conveniente incorporar otras bases de datos en este tipo de estudios, como observaciones de estaciones meteorológicas, distintos tipos de reanálisis (ERA5, CFSR, entre otros), datos derivados de satélite (TRMM, GPM) e incluso el Cubo de Datos del Ideam, con el fin de enriquecer la calidad de los análisis.

Se sugiere incluir métricas de verificación de rendimiento para las predicciones probabilísticas, tales como las asociadas al ROC (*Receiver Operating Characteristic* o Característica Operativa del Receptor), que permiten evaluar discriminadamente el rendimiento de los modelos.

Referencias bibliográficas

- Alfaro, E. J. (2007). Uso del análisis de correlación canónica para la predicción de la precipitación pluvial en Centroamérica. *Ingeniería y Competitividad*, 9, 33-48. <https://doi.org/10.25100/ijc.v9i2.2486>
- Amador, J. A. y Alfaro, E. (2009). Métodos de reducción de escala: Aplicaciones al tiempo, clima, variabilidad climática y cambio climático. *Revista Iberoamericana de Economía Ecológica (REVIBEC)*, 11, 39-52. https://ddd.uab.cat/pub/revibec/revibec_a2009v11/revibec_a2009v11p39.pdf
- CIIFEN (2011). *Guía de buenas prácticas en predicción estacional-Latinoamérica*. Centro Internacional para la Investigación del Fenómeno de El Niño. https://www.researchgate.net/publication/256980652_Guia_de_Buenas_practicas_en_prediccion_Estacional-Latinoamerica
- Díaz, D. y Villegas, N. (2015). Correlación canónica entre índices macroclimáticos y variables meteorológicas de superficie en Colombia. *Revista U.D.C.A. Actualidad & Divulgación Científica*, 18(2), 543-552. <http://www.scielo.org.co/pdf/ru-dca/v18n2/v18n2a28.pdf>
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., Huzak, G., Rowland, J., Harrison, L., Hoell, A. y Michaelson, J. (2015). The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Scientific Data*, 2, 150066. <https://doi.org/10.1038/sdata.2015.66>
- Kirtman, B. P., Min, D., Infanti, J. M., Kinter, J. L. III, Paolino, D. A., Zhang, Q., van den Dool, H., Saha, S., Mendez, M. P., Becker, E., Peng, P., Tripp, P., Huang, J., DeWitt, D. G., Tzippe, M. K., Barnston, A. G., Li, S., Rosati, A., Schubert, S. D., ... Wood, E. F. (2014). The North American Multimodel Ensemble: Phase-1 seasonal-to-interannual prediction; phase-2 toward developing intraseasonal prediction. *Bulletin of the American Meteorological Society*, 95(4), 585-601. <https://doi.org/10.1175/BAMS-D-12-00050.1>
- Martínez Pedraza, A., y Serna Cuenca, J. (2018). *Validación de las estimaciones de precipitación con CHIRPS e IRE/IDEAM*. (Nota Técnica IDEAM-METEO/002-2018). Instituto de Hidrología, Meteorología y Estudios Ambientales – IDEAM. http://bart.ideam.gov.co/wrfideam/new_modelo/DOCUMENTOS/2018/NT_IDEAM-002-2018.pdf
- Trocchi, A. Harrison, M., Anderson, D. Mason, S. J. (2008). Statistical modelling. *Seasonal Climate: Forecasting and Managing Risk*. Springer, 163 – 201. <https://link.springer.com/book/10.1007/978-1-4020-6992-5>
- Muñoz, C. (2009). Variabilidad interanual de la precipitación invernal en Chile central no asociada al ciclo El Niño-Oscilación del Sur (Tesis de grado, Universidad de Concepción). https://www.dgeo.udec.cl/wp-content/uploads/2012/09/muñoz-cristian_tesis.pdf
- Muñoz, A.G. (2019). agmunozs/PyCPT: PyCPTV1.5 (v 1.5) Zenodo. <https://doi.org/10.5281/zenodo.3551936>
- Organización Meteorológica Mundial (OMM). (2019). *Guidance on operational practices for objective seasonal forecasting (WMO-No. 1246)*. https://library.wmo.int/index.php?lvl=notice_display&id=21741#.Yldcs8jMJPY
- Urrea, V., Ochoa, A. y Mesa, O. (2016, 28-30 de septiembre). *Validación de la base de datos de precipitación CHIRPS para Colombia a escala diaria, mensual y anual en el período 1981-2014* [ponencia]. XXVII Congreso Latinoamericano de Hidráulica, Lima, Perú. Universidad Nacional de Colombia, Sede Medellín. https://www.researchgate.net/publication/310844678_Validacion_de_la_base_de_datos_de_precipitacion_CHIRPS_para_Colombia_a_escalas_diaria_mensual_y_anual_en_el_periodo_1981-2014
- Wilks, D. S. (2006). *Statistical methods in the atmospheric sciences* (2ª ed.). International Geophysics Series. Academic Press. <https://sunandclimate.files.wordpress.com/2009/05/statistical-methods-in-the-atmospheric-sciences-0127519661.pdf>
- World Climate Research Project (WCRP) (2015). *7th International Verification Methods Workshop*. <https://cawcr.gov.au/projects/verification/>


Anexo 1. Contribución de cada modelo de la NOAA al ensamble de predicción

En esta sección se presentan de manera gráfica los resultados correspondientes a las tablas 2 a 13, con el objetivo de facilitar la visualización de la contribución


porcentual de cada modelo de la NOAA al ensamble de predicción a nivel nacional.

Figura 13. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de enero


CI: Enero - Predicción: Febrero




CI: Enero - Predicción: Marzo




CI: Enero - Predicción: Abril



CI: Enero - Predicción: Mayo



CI: Enero - Predicción: Junio



CI: Enero - Predicción: Julio






Figura 14. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de febrero

CI: Febrero - Predicción: Marzo




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Febrero - Predicción: Abril




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Febrero - Predicción: Mayo




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Febrero - Predicción: Junio




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Febrero - Predicción: Julio



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


CI: Febrero - Predicción: Agosto




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

Figura 15. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de marzo


CI: Marzo - Predicción: Abril




CI: Marzo - Predicción: Mayo




CI: Marzo - Predicción: Junio



CI: Marzo - Predicción: Julio



CI: Marzo - Predicción: Agosto



CI: Marzo - Predicción: Septiembre





Figura 16. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de abril

CI: Abril - Predicción: Mayo




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Abril - Predicción: Junio




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Abril - Predicción: Julio




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Abril - Predicción: Agosto




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Abril - Predicción: Septiembre



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


CI: Abril - Predicción: Octubre



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


Figura 17. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de mayo

CI: Mayo Predicción: Junio




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Mayo Predicción: Julio




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Mayo Predicción: Agosto




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Mayo Predicción: Septiembre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Mayo Predicción: Octubre



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


CI: Mayo Predicción: Noviembre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

Figura 18. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de junio


CI: Junio - Predicción: Julio




CI: Junio - Predicción: Agosto




CI: Junio - Predicción: Septiembre



CI: Junio - Predicción: Octubre



CI: Junio - Predicción: Noviembre



CI: Junio - Predicción: Diciembre


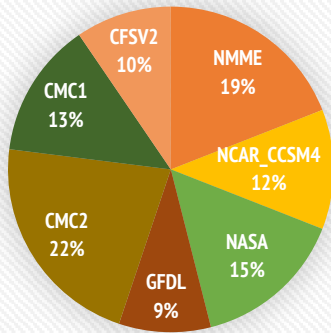



Figura 19. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de julio

CI: Julio - Predicción: Agosto




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Julio - Predicción: Septiembre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Julio - Predicción: Octubre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Julio - Predicción: Noviembre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Julio - Predicción: Diciembre



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


CI: Julio - Predicción: Enero



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


Figura 20. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de agosto

CI: Agosto - Predicción: Septiembre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Agosto - Predicción: Octubre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Agosto - Predicción: Noviembre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Agosto - Predicción: Diciembre



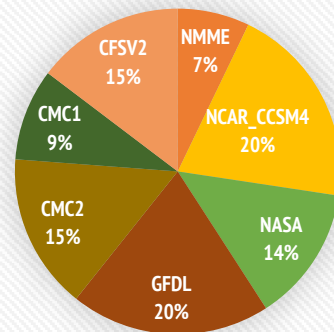
■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Agosto - Predicción: Enero



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


CI: Agosto - Predicción: Febrero



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


Figura 21. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de septiembre

CI: Septiembre - Predicción: Octubre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Septiembre - Predicción: Noviembre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Septiembre - Predicción: Diciembre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Septiembre - Predicción: Enero




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Septiembre - Predicción: Febrero



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


CI: Septiembre - Predicción: Marzo



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


Figura 22. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de octubre

CI: Octubre - Predicción: Noviembre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Octubre - Predicción: Diciembre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Octubre - Predicción: Enero




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Octubre - Predicción: Febrero




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Octubre - Predicción: Marzo



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


CI: Octubre - Predicción: Abril



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


Figura 23. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de noviembre

CI: Noviembre - Predicción: Diciembre




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Noviembre - Predicción: Enero




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Noviembre - Predicción: Febrero




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Noviembre - Predicción: Marzo




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Noviembre - Predicción: Abril



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


CI: Noviembre - Predicción: Mayo



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2


Figura 24. Aporte de cada modelo del CPC-NOAA a la predicción mensual para los siguientes seis meses de predicción tomando condiciones iniciales de diciembre

CI: Diciembre - Predicción: Enero




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Diciembre - Predicción: Febrero




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Diciembre - Predicción: Marzo




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Diciembre - Predicción: Abril




■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Diciembre - Predicción: Mayo



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2

CI: Diciembre - Predicción: Junio



■ NMME ■ NCAR_CCSM4 ■ NASA ■ GFDL ■ CMC2 ■ CMC1 ■ CFSV2



Ambiente



IDEAM